

**VŠB – Technická univerzita Ostrava**  
**Fakulta elektrotechniky a informatiky**  
**Katedra kybernetiky a biomedicínského inženýrství**

**Vliv přírodního radiačního pozadí na paměťové fólie pro  
nepřímou digitalizaci obrazu**  
**Effect of Natural Radiation Background on Memory Films for  
Indirect Image Digitalization**

VŠB - Technická univerzita Ostrava  
Fakulta elektrotechniky a informatiky  
Katedra kybernetiky a biomedicínského inženýrství

## Zadání diplomové práce

Student:

**Bc. Ivana Bambušková**

Studijní program:

N2649 Elektrotechnika

Studijní obor:

3901T009 Biomedicínské inženýrství

Téma:

Vliv přírodního radiačního pozadí na paměťové fólie pro nepřímou digitalizaci obrazu  
Effect of Natural Radiation Background on Memory Films for Indirect Image Digitalization

Jazyk vypracování:

čeština

Zásady pro vypracování:

1. Studium vlivu přírodního radiačního pozadí na kvalitu obrazu v nepřímé digitalizaci.
2. Nastudování problematiky měření a snímání přírodního radiačního pozadí.
3. Design a realizace experimentů pro analýzu vlivu přírodního radiačního pozadí v závislosti na délce expozice paměťové fólie.
4. Návrh matematického modelu pro objektivizované hodnocení vlivu přírodní radiace na kvalitu paměťových fólií.
5. Návrh predikčního modelu pro modelování závislosti délky expozice přírodním radiačním pozadím ve vztahu ke kvalitě zobrazení.
6. Evaluace a testování navržených procedur na reálných datech.
7. Vyhodnocení výsledků práce.

Seznam doporučené odborné literatury:

- [1] DHAWAN, Atam P. *Medical image analysis*. Hoboken: Wiley, c2003. IEEE Press series on biomedical engineering. ISBN 0-471-45131-2.
- [2] MCANDREW, Alasdair. *Introduction to digital image processing with MATLAB*. Boston: Thomson Course Technology, c2004. ISBN 0-534-40011-6.
- [3] SINGER, Jan. *Dozimetrie ionizujícího záření*. České Budějovice: Jihočeská univerzita, Zdravotně sociální fakulta, 2005. ISBN 80-7040-752-2.
- [4] ANTONI, Rodolphe a Laurent BOURGOIS. *Applied physics of external radiation exposure: dosimetry and radiation protection*. Cham: Springer, 2017. Biological and medical physics, biomedical engineering. ISBN 978-3-319-48658-1.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Jan Kubíček, Ph.D.**

Datum zadání: 01.09.2019

Datum odevzdání: 30.04.2020



doc. Ing. Jiří Koziorek, Ph.D.  
*vedoucí katedry*



prof. Ing. Pavel Brandštetter, CSc.  
*děkan fakulty*

## Prohlášení studenta

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně. Uvedla jsem všechny literární publikace a prameny, ze kterých jsem čerpala.

Datum: 5.5.2020



Bc. Ivana Bambušková



## **Poděkování**

Ráda bych poděkovala vedoucímu mé diplomové práce panu Ing. Janu Kubíčkovi, Ph.D. za pomoc, podporu a věcné rady k mé práci, dále panu Ing. Michalu Koláčkovi za zapůjčení měřicích přístrojů a panu RNDr. Vojtěchu Ullmannovi za konzultace k experimentálnímu měření.

## **Abstrakt**

Ionizující záření je možno rozdělit do dvou základních skupin, a to do uměle vytvořených a do skupiny přirozeně vytvořených. Práce se zabývá druhou formou, a to přírodní radiací, ta se vyskytuje na Zemi zcela běžně. Jak ale přírodní radiace může působit na skiagrafické kazety pro nepřímou digitalizaci nebylo zatím zcela objasněno. Nepřímá digitalizace je totiž stále značně využívanou metodou v oblasti radiologie a je vhodné vědět, jakým způsobem může ionizující záření působit na degradaci kazet. Společně s obrazovým měřením se získávají také data o hodnotě dávky v měřeném místě. Dynamický efekt šumu v průběhu expozice na základě radiačního pozadí je evaluován s využitím regionálně orientované segmentace, klasifikující obraz do regionů, které odrážejí dynamiku působení šumu v průběhu měření. Díky vhodně zvolené prahovací technice je provedena řada statistických analýz, zahrnující deskriptivní statistiku, dvouvýběrové a vícevýběrové testy. Následně je vytvořen predikční model pro degradaci kazety.

## **Klíčová slova**

Přírodní radiační pozadí, dozimetrie, nepřímá digitalizace, zpracování obrazu, Fuzzy prahování.

## **Abstract**

Ionizing radiation can be divided into two basic groups, namely artificially created and naturally created. The thesis deals with the second form, namely natural radiation, which occurs on Earth quite commonly. However, how natural radiation can affect skiagraphic cassettes for indirect digitization has not yet been fully elucidated. Indirect digitization is still a widely used method in radiology and it is advisable to know how ionizing radiation can affect cassette degradation. Along with the image measurement, data on the dose value at the measured site is also obtained. The dynamic effect of noise during exposure based on radiation background is evaluated using regionally oriented segmentation, classifying the image into regions that reflect the dynamics of noise action during measurement. Thanks to the appropriately chosen thresholding method, a number of statistical analyses are carried out, including descriptive statistics, two-sample and multi-sample tests. A prediction model for cassette degradation is subsequently created.

## **Key words**

Natural radiation background, dosimetry, indirect digitization, image processing, Fuzzy thresholding

# Obsah

|  |    |
|--|----|
| Seznam použitých symbolů.....  | 12 |
| Seznam použitých zkratk.....   | 13 |
| Seznam ilustrací .....   | 14 |
| Seznam tabulek .....   | 17 |
| Úvod .....   | 19 |
| 1 Ionizující záření.....   | 20 |
| 1.1 Základní typy záření .....   | 20 |
| 1.1.1 Záření alfa .....  | 20 |
| 1.1.2 Záření beta .....  | 20 |
| 1.1.3 Záření gama a RTG.....   | 21 |
| 1.1.4 Neutronové záření.....   | 21 |
| 1.2 Umělé zdroje ionizujícího záření .....   | 21 |
| 1.3 Přírodní zdroje ionizujícího záření.....   | 21 |
| 1.3.1 Kosmogenní radionuklidy.....   | 22 |
| 1.3.2 Primordiální radionuklidy .....  | 22 |
| 1.3.3 Sekundární radionuklidy .....  | 22 |
| 1.3.4 Radioaktivní rozpadové řady .....  | 23 |
| 1.4 Pozadí ionizujícího záření: obrazová perspektiva.....                              | 24 |
| 2 Základní veličiny v dozimetrii .....   | 25 |
| 2.1 Expozice a expoziční příkon.....   | 25 |
| 2.2 Kerma a kermový příkon .....   | 26 |
| 2.3 Absorbovaná dávka a dávkový příkon.....  | 26 |
| 3 Degradace materiálů vlivem radiace .....   | 27 |
| 3.1 Radiační poškození .....   | 27 |
| 3.1.1 Pružné (elastické) srážky .....  | 27 |
| 3.1.2 Nepružné (inelastické) srážky .....  | 27 |
| 3.2 Vliv záření na materiály .....   | 28 |
| 3.3 Citlivost kazet pro nepřímou digitalizaci obrazu na přírodní radiační pozadí ..... | 28 |
| 3.4 Vliv ionizujícího záření na vlastnosti polymerů .....                              | 29 |
| 3.5 Modelování a analýza efektu ionizujícího záření na paměťových fóliích .....        | 30 |
| 3.6 Vliv sekundárního rentgenového záření na kvalitu skiagrafických snímků .....       | 31 |
| 4 Radiometrická měřicí technika .....  | 32 |

|       |   |    |
|-------|---|----|
| 4.1   | Elektrické detektory .....                      | 32 |
| 4.1.1 | Ionizační komory .....                          | 33 |
| 4.1.2 | Geiger-Müllerovy počítače .....                 | 33 |
| 4.2   | Scintilační detektory .....                     | 34 |
| 4.3   | Filmové dozimetry .....                         | 34 |
| 4.4   | Termoluminiscenční dozimetry .....              | 35 |
| 4.5   | OSL dozimetry .....                             | 35 |
| 5     | Digitální radiografie a záření X.....           | 36 |
| 5.1   | Digitální radiografie.....                      | 36 |
| 5.2   | Nepřímá radiografie .....                       | 36 |
| 5.3   | Přímá radiografie .....                         | 36 |
| 5.4   | Rentgenka a vznik RTG záření .....              | 37 |
| 6     | Segmentační techniky pro zpracování obrazu..... | 38 |
| 6.1   | Statistické metody .....                        | 38 |
| 6.1.1 | Prahování .....                                 | 38 |
| 6.1.2 | Adaptivní prahování .....                       | 40 |
| 6.1.3 | Shluková analýza – Clustering .....             | 41 |
| 6.1.4 | Kohonenovy mapy .....                           | 41 |
| 1.1.1 | Markov Random Fields (MRF) .....                | 41 |
| 6.2   | Detekce hran – edge-based .....                 | 42 |
| 6.2.1 | Hranové detektory.....                          | 42 |
| 6.2.2 | Houghovy transformace.....                      | 42 |
| 6.2.3 | Aktivní kontury.....                            | 42 |
| 6.2.4 | Level-set metoda.....                           | 43 |
| 6.3   | Region-based metoda.....                        | 43 |
| 6.3.1 | Region growing.....                             | 43 |
| 6.3.2 | Split and merge .....                           | 43 |
| 6.4   | Hybridní metody .....                           | 44 |
| 6.4.1 | Watershed transformace .....                    | 44 |
| 6.4.2 | Neuronové sítě .....                            | 44 |
| 7     | Použité vybavení .....                          | 45 |
| 7.1   | Polimaster PM-1621 .....                        | 45 |
| 8     | Experiment akvizice obrazů a hodnoty dávek..... | 46 |

|        |   |    |
|--------|---|----|
| 8.1    | Časově závislá data .....   | 48 |
| 9      | Komparativní analýza regionálně orientovaných segmentačních modelů .....  | 52 |
| 9.1    | Komparativní analýza metod Fuzzy a OTSU .....   | 52 |
| 9.1.1  | Šumová analýza pro 3 regiony .....  | 53 |
| 9.1.2  | Šumová analýza pro 5 regionů .....  | 54 |
| 9.1.3  | Šumová analýza pro 10 regionů .....   | 56 |
| 9.1.4  | Zhodnocení .....  | 57 |
| 9.2    | Výběr segmentační metody a počtu regionů pro segmentaci .....   | 57 |
| 9.2.1  | 24 hodin – 2 regiony .....  | 57 |
| 9.2.2  | 24 hodin – 5 regionů .....  | 58 |
| 9.2.3  | 24 hodin - 10 regionů .....   | 59 |
| 9.2.4  | 4 týdny – 2 regiony .....   | 60 |
| 9.2.5  | 4 týdny - 5 regionů .....   | 61 |
| 9.2.6  | 4 týdny – 10 regionů .....  | 62 |
| 9.3    | Zhodnocení a zdůvodnění výběru .....  | 63 |
| 10     | Návrh matematického modelu pro objektivizované hodnocení vlivu přírodní radiace na kvalitu paměťových fólií .....     | 65 |
| 11     | Statistická analýza časově-závislých charakteristik vlivu radiačního pozadí na kazety pro nepřímou digitalizaci ..... | 73 |
| 11.1   | Použité proměnné a metody statistiky .....  | 73 |
| 11.2   | Závislost distribuce pixelů na čase .....   | 76 |
| 11.3   | Deskriptivní statistické údaje pro druhou sérii měření .....  | 79 |
| 11.4   | Statistická analýza druhé série měření pro region 1 .....   | 81 |
| 11.4.1 | Dvouvýběrové charakteristiky pro region 1 .....   | 81 |
| 11.4.2 | Vícevýběrové charakteristiky pro region 1 .....   | 85 |
| 11.5   | Statistická analýza druhé série měření pro region 2 .....   | 86 |
| 11.5.1 | Dvouvýběrové charakteristiky pro region 2 .....   | 86 |
| 11.5.2 | Vícevýběrové charakteristiky pro region 2 .....   | 90 |
| 11.6   | Statistická analýza druhé série měření pro region 3 .....   | 91 |
| 11.6.1 | Dvouvýběrové charakteristiky pro region 3 .....   | 91 |
| 11.6.2 | Vícevýběrové charakteristiky pro region 3 .....   | 95 |
| 11.7   | Statistická analýza druhé série měření pro region 4 .....   | 96 |
| 11.7.1 | Dvouvýběrové charakteristiky pro region 4 .....   | 96 |
| 11.7.2 | Více výběrové charakteristiky pro region 4 .....  | 99 |

|         |   |     |
|---------|---|-----|
| 11.8    | Statistická analýza druhé série měření pro region 5 .....   | 101 |
| 11.8.1  | Dvouvýběrové charakteristiky pro region 5 .....   | 101 |
| 11.8.2  | Vícevýběrové charakteristiky pro region 5 .....   | 105 |
| 11.9    | Deskriptivní statistické údaje pro první sérii měření .....   | 106 |
| 11.10   | Statistická analýza první série měření pro region 1 .....   | 108 |
| 11.10.1 | Dvouvýběrové charakteristiky pro region 1 .....   | 108 |
| 11.10.2 | Vícevýběrové charakteristiky pro region 1 .....   | 112 |
| 11.11   | Statistická analýza první série měření pro region 2 .....   | 113 |
| 11.11.1 | Dvouvýběrové charakteristiky pro region 2 .....   | 113 |
| 11.11.2 | Vícevýběrové charakteristiky pro region 2 .....   | 117 |
| 11.12   | Statistická analýza první série měření pro region 3 .....   | 118 |
| 11.12.1 | Dvouvýběrové charakteristiky pro region 3 .....   | 118 |
| 11.12.2 | Vícevýběrové charakteristiky pro region 3 .....   | 122 |
| 11.13   | Statistická analýza první série měření pro region 4 .....   | 123 |
| 11.13.1 | Dvouvýběrové charakteristiky pro region 4 .....   | 123 |
| 11.13.2 | Vícevýběrové charakteristiky pro region 4 .....   | 127 |
| 11.14   | Statistická analýza první série měření pro region 5 .....   | 128 |
| 11.14.1 | Dvouvýběrové charakteristiky pro region 5 .....   | 128 |
| 11.14.2 | Vícevýběrové charakteristiky pro region 5 .....   | 132 |
| 11.15   | Shrnutí statistické analýzy .....   | 132 |
| 12      | Návrh predikčního modelu pro modelování závislosti míry poškození paměťové fólie na<br>dozimetrickém měření ..... | 133 |
| 12.1    | Lineární predikční model .....  | 133 |
| 12.2    | Nelineární predikční model .....  | 138 |
|         | Diskuze .....   | 144 |
|         | Závěr .....   | 145 |
|         | Seznam použitých zdrojů .....   | 146 |
|         | Přílohy .....   | 150 |

## Seznam použitých symbolů

| Symbol               | Jednotky     | Význam symbolu          |
|----------------------|--------------|-------------------------|
| $c$                  | m/s          | Rychlost světla         |
| $D$                  | Gy/s či Sv/s | Dávka                   |
| $E$                  | J, eV        | Energie                 |
| $E^*$                | J            | Ztráta energie          |
| $f$                  | Hz           | Frekvence záření        |
| $h$                  | Js           | Planckova konstanta     |
| $K$                  | Gy           | Kerma                   |
| $m$                  | kg           | Hmotnost                |
| $M$                  | kg           | Hmotnost atomu          |
| $Q$                  | C            | Elektrický náboj        |
| $t$                  | s            | Čas                     |
| $T$                  | J            | Kinetická energie       |
| $v$                  | m/s          | Rychlost                |
| $x$                  | m            | Dráha                   |
| $X$                  | C/kg         | Expozice                |
| $\alpha$             |              | Záření alfa             |
| $\beta$              |              | Záření beta             |
| $\theta$             | °            | Úhel rozptylu           |
| $\lambda$            | m            | Vlnová délka            |
| $\mu_0, \mu_1$       |              | Třídní průměry          |
| $\omega_0, \omega_1$ |              | Třídní pravděpodobnosti |



## Seznam použitých zkratk

| Zkratka     | Význam                           |
|-------------|----------------------------------|
| <b>A/D</b>  | Analogově-digitální              |
| <b>Ar</b>   | Argon                            |
| <b>B</b>    | Bor                              |
| <b>Be</b>   | Berylium                         |
| <b>C</b>    | Uhlík                            |
| <b>G-M</b>  | Geiger-Müller                    |
| <b>GRBF</b> | Radial basis function network    |
| <b>Gy</b>   | Gray                             |
| <b>HDPE</b> | High Density Polyethylene        |
| <b>IP</b>   | Index of Protection              |
| <b>K</b>    | Draslík                          |
| <b>LDPE</b> | Low Density Polyethylene         |
| <b>Li</b>   | Lithium                          |
| <b>MeV</b>  | Mega elektron-Volt               |
| <b>MPa</b>  | Mega Pascal                      |
| <b>MRF</b>  | Markov Random Fields             |
| <b>mSv</b>  | Mili-Sievert                     |
| <b>OSL</b>  | Opticky stimulovaná luminiscence |
| <b>P</b>    | Fosfor                           |
| <b>Pu</b>   | Plutonium                        |
| <b>RTG</b>  | Rentgenové                       |
| <b>S</b>    | Síra                             |
| <b>Th</b>   | Thorium                          |
| <b>TLD</b>  | Termoluminiscenční dozimetry     |
| <b>U</b>    | Uran                             |

## Seznam ilustrací

|  |    |
|--|----|
| Obrázek 1: Rozdělení dávek pro obyvatelstvo [upraveno z 5].....  | 23 |
| Obrázek 2: Veličiny v dozimetrii [10] .....  | 25 |
| Obrázek 3: Blokové schéma radiometrické aparatury [3].....   | 32 |
| Obrázek 4: Schéma ionizační komory [13].....   | 33 |
| Obrázek 5: Schéma G-M počítače [13].....   | 34 |
| Obrázek 6: Schéma scintilačního detektoru [13] .....   | 34 |
| Obrázek 7: Termoluminiscenční dozimetry, OSL dozimetry, schéma principu [13] .....                       | 35 |
| Obrázek 8: Struktura paměťové fólie [11] .....   | 36 |
| Obrázek 9: Charakteristická funkce [23].....   | 39 |
| Obrázek 10: Multilevel OTSU metoda .....   | 40 |
| Obrázek 11: Shluková analýza [26] .....  | 41 |
| Obrázek 12: Typy hran [19].....  | 42 |
| Obrázek 13: Aktivní kontury [27].....  | 42 |
| Obrázek 14: Region growing [28].....   | 43 |
| Obrázek 15: Watershed transformace [29].....   | 44 |
| Obrázek 16: Neuronové sítě [30] .....  | 44 |
| Obrázek 17: Dozimetr Polimaster PM-1621 [31] .....   | 45 |
| Obrázek 18: Obraz po působení přírodní radiace a obraz v olověném boxu, oba po expozici za 1 týden ..... | 46 |
| Obrázek 19: Segmentace pěti regiony u snímku po expozici za týden .....                                  | 47 |
| Obrázek 20: Segmentace pěti regiony u snímku po expozici za týden v olověném boxu .....                  | 47 |
| Obrázek 21: Graf závislosti dávky na čase .....  | 48 |
| Obrázek 22: Zleva: Referenční obraz za 0 minut, obraz za 24 hodin .....                                  | 49 |
| Obrázek 23: Zleva: Obraz za 1 týden, obraz za 2 týdny .....  | 49 |
| Obrázek 24: Zleva: Obraz za 3 týdny a za 4 týdny .....   | 50 |
| Obrázek 25: Snímky za 0 minut, 24 hodin, 48 hodin, 4, 8, 16 a 32 dní .....                               | 51 |
| Obrázek 26: Grafy MSE a korelace pro Gaussovský šum pro 3 regiony.....                                   | 53 |
| Obrázek 27: Grafy MSE a korelace pro šum Salt & Pepper pro 3 regiony.....                                | 53 |
| Obrázek 28: MSE a korelace pro šum Speckle pro 3 regiony.....  | 54 |
| Obrázek 29: MSE a korelace pro Gaussovský šum pro 5 regionů.....   | 54 |
| Obrázek 30: MSE a korelace pro šum Salt & Pepper pro 5 regionů.....                                      | 55 |
| Obrázek 31: MSE a korelace pro šum Speckle pro 5 regionů.....  | 55 |
| Obrázek 32: MSE a korelace pro Gaussovský šum pro 10 regionů .....                                       | 56 |
| Obrázek 33: MSE a korelace pro šum Salt & Pepper pro 10 regionů.....                                     | 56 |
| Obrázek 34: MSE a korelace pro šum Speckle pro 10 regionů.....   | 57 |
| Obrázek 35: Snímky po segmentaci 2 regiony.....  | 58 |
| Obrázek 36: Snímky po binarizaci a původní snímek.....   | 58 |
| Obrázek 37: Snímky po segmentaci 5 regiony.....  | 59 |
| Obrázek 38: Snímky po binarizaci a původní snímek.....   | 59 |
| Obrázek 39: Snímky po segmentaci 10 regiony.....   | 60 |
| Obrázek 40: Snímky po binarizaci a původní snímek.....   | 60 |
| Obrázek 41: Snímky po segmentaci 2 regiony.....  | 61 |

|  |     |
|--|-----|
| Obrázek 42: Snímky po binarizaci a původní snímek.....   | 61  |
| Obrázek 43: Snímky po segmentaci 5 regiony.....  | 62  |
| Obrázek 44: Snímky po binarizaci a původní snímek.....   | 62  |
| Obrázek 45: Snímky po segmentaci 10 regiony.....   | 63  |
| Obrázek 46: Snímky po binarizaci a původní snímek.....   | 63  |
| Obrázek 47: Vývojový diagram procesu získání vektoru jasových složek.....  | 65  |
| Obrázek 48: Zleva: Referenční obraz zpracovaný metodou Fuzzy a jeho histogram.....                               | 66  |
| Obrázek 49: Segmentace pěti regiony pro obrazy za 24 hodin, 1, 2, 3 a 4 týdny a jejich příslušné histogramy..... | 68  |
| Obrázek 50: Shora: Snímek za 0 minut, 24 hodin, 48 hodin, 4, 8, 16 a 32 dnů a jejich příslušné histogramy.....   | 71  |
| Obrázek 51: Matice segmentovaného obrazu .....   | 72  |
| Obrázek 52: Kód pro tvorbu binární masky.....  | 72  |
| Obrázek 53: QQ grafy [vlastní zdroj] .....   | 74  |
| Obrázek 54: Boxplot [vlastní zdroj].....   | 74  |
| Obrázek 55: Histogram s proloženou ideální Gaussovskou křivkou [38].....   | 74  |
| Obrázek 56: Zleva: Vývojový diagram pro dvouvýběrové testy a pro vícevýběrové testy .....                        | 76  |
| Obrázek 57: Závislost počtu pixelů na čase pro jednotlivé segmentační třídy ve druhé sérii měření....            | 77  |
| Obrázek 58: Závislost počtu pixelů na čase pro jednotlivé segmentační třídy v první sérii měření.....            | 78  |
| Obrázek 59: Boxploty pro region 1 – 0 minut, 1, 2, 3 a 4 týdny a 24 hodin.....                                   | 82  |
| Obrázek 60: QQ grafy pro region 1 z druhé série měření .....   | 82  |
| Obrázek 61: Histogramy pro region 1 za 0 minut, 24 hodin, 1, 2, 3 a 4 týdny .....                                | 83  |
| Obrázek 62: Boxploty pro region 2 – 0 minut, 1, 2, 3 a 4 týdny a 24 hodin.....                                   | 87  |
| Obrázek 63: QQ grafy pro region 2 z druhé série měření .....   | 87  |
| Obrázek 64: Histogramy pro region 2 za 0 minut, 24 hodin, 1, 2, 3 a 4 týdny .....                                | 88  |
| Obrázek 65: Boxploty pro region 3 – 0 minut, 1, 2, 3 a 4 týdny a 24 hodin.....                                   | 92  |
| Obrázek 66: QQ grafy pro region 3 ze druhé série měření .....  | 92  |
| Obrázek 67: Histogramy pro region 3 ve druhé sérii měření .....  | 93  |
| Obrázek 68: Boxploty pro region 4 – 1, 2, 3 a 4 týdny a 24 hodin .....   | 97  |
| Obrázek 69: QQ grafy pro region 4 pro druhou sérii měření .....  | 97  |
| Obrázek 70: Histogramy pro region 4 ve druhé sérii měření .....  | 98  |
| Obrázek 71: Boxploty pro region 5 – 0 minut, 1, 2, 3 a 4 týdny a 24 hodin.....                                   | 102 |
| Obrázek 72: QQ grafy pro region 5 ve druhé sérii měření.....   | 102 |
| Obrázek 73: Histogramy pro region 5 ve druhé sérii měření .....  | 103 |
| Obrázek 74: Boxploty pro region 1 – 0 minut, 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin.....                      | 109 |
| Obrázek 75: QQ grafy pro region 1 v první sérii měření .....   | 109 |
| Obrázek 76: Histogramy pro region 1 v první sérii měření .....   | 110 |
| Obrázek 77: Boxploty pro region 2 – 0 minut, 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin.....                      | 114 |
| Obrázek 78: QQ grafy pro region 2 ve druhé sérii měření.....   | 114 |
| Obrázek 79: Histogramy regionu 2 v první sérii měření.....   | 115 |
| Obrázek 80: Boxploty pro region 3 – 0 minut, 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin.....                      | 119 |
| Obrázek 81: QQ grafy pro region 3 v první sérii měření .....   | 119 |
| Obrázek 82: Histogramy pro region 3 v první sérii měření .....   | 120 |
| Obrázek 83: Boxploty pro region 4 – 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin.....                               | 124 |

|  |     |
|--|-----|
| Obrázek 84: QQ grafy pro region 4 v první sérii měření .....   | 124 |
| Obrázek 85: Histogramy pro region 4 v první sérii měření .....   | 125 |
| Obrázek 86: Boxploty pro region 5 – 0 minut, 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin.....                                | 129 |
| Obrázek 87: QQ grafy pro region 5 v první sérii měření .....   | 129 |
| Obrázek 88: Histogramy pro region 5 v první sérii měření .....   | 130 |
| Obrázek 89: Polynomiální predikční model pro počet vzorků v regionu 5 v závislosti na dávce ve druhé sérii měření.....     | 134 |
| Obrázek 90: Polynomiální predikční model pro mediány všech regionů v závislosti na dávce ve druhé sérii měření.....        | 135 |
| Obrázek 91: Polynomiální predikční model pro mediány v regionu 1 v závislosti na dávce ve druhé sérii měření.....          | 135 |
| Obrázek 92: Polynomiální predikční model pro počet vzorků v regionu 2 v závislosti na dávce v první sérii měření.....      | 136 |
| Obrázek 93: Polynomiální predikční model pro počet vzorků v regionu 5 v závislosti na dávce v první sérii měření.....      | 137 |
| Obrázek 94: Polynomiální predikční model pro mediány pro všechny regiony v závislosti na dávce v první sérii měření .....  | 137 |
| Obrázek 95: Polynomiální predikční model pro mediány v regionu 1 v závislosti na dávce v první sérii měření.....           | 138 |
| Obrázek 96: Exponenciální predikční model pro počet vzorků v regionu 5 v závislosti na dávce ve druhé sérii měření.....    | 139 |
| Obrázek 97: Exponenciální predikční model pro mediány ve všech regionech v závislosti na dávce ve druhé sérii měření.....  | 140 |
| Obrázek 98: Exponenciální predikční model pro mediány v regionu 1 v závislosti na dávce ve druhé sérii měření.....         | 140 |
| Obrázek 99: Exponenciální predikční model pro počet vzorků v regionu 2 v závislosti na dávce v první sérii měření.....     | 141 |
| Obrázek 100: Exponenciální predikční model pro počet vzorků v regionu 5 v závislosti na dávce v první sérii měření.....    | 142 |
| Obrázek 101: Exponenciální predikční model pro mediány ve všech regionech v závislosti na dávce v první sérii měření ..... | 142 |
| Obrázek 102: Exponenciální predikční model pro mediány v regionu 1 v závislosti na dávce v první sérii měření.....         | 143 |

## Seznam tabulek

|   |     |
|---|-----|
| Tabulka 1: Základní parametry dozimetru Polimaster [31] .....                                       | 45  |
| Tabulka 2: Hodnoty dávek v závislosti na rostoucím čase .....                                       | 48  |
| Tabulka 3: Distribuce pixelů v závislosti na čase pro druhou sérii měření .....                     | 76  |
| Tabulka 4: Distribuce pixelů v závislosti na čase pro první sérii měření .....                      | 77  |
| Tabulka 5: Deskriptivní statistické údaje pro všechny časy v rámci jednoho regionu .....            | 79  |
| Tabulka 6: Deskriptivní statistické údaje pro všechny regiony v rámci jednoho časového úseku .....  | 80  |
| Tabulka 7: Deskriptivní statistické údaje pro region 1 ve druhé sérii měření .....                  | 81  |
| Tabulka 8: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 1 .....                  | 83  |
| Tabulka 9: Dvouvýběrové charakteristiky pro region 1 ve všech kombinacích .....                     | 84  |
| Tabulka 10: Kruskal-Wallisův test pro region 1 .....  | 85  |
| Tabulka 11: Deskriptivní statistické údaje pro region 2 ve druhé sérii měření .....                 | 86  |
| Tabulka 12: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 2 .....                 | 88  |
| Tabulka 13: Dvouvýběrové charakteristiky pro region 2 ve všech kombinacích .....                    | 89  |
| Tabulka 14: Kruskal-Wallisův test pro region 2 .....  | 90  |
| Tabulka 15: Deskriptivní statistické údaje pro region 3 ve druhé sérii měření .....                 | 91  |
| Tabulka 16: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 3 .....                 | 93  |
| Tabulka 17: Dvouvýběrové charakteristiky pro region 3 ve všech kombinacích .....                    | 94  |
| Tabulka 18: Kruskal-Wallisův test pro region 3 .....  | 95  |
| Tabulka 19: Deskriptivní statistické údaje pro region 4 ve druhé sérii měření .....                 | 96  |
| Tabulka 20: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 4 .....                 | 98  |
| Tabulka 21: Dvouvýběrové charakteristiky pro region 4 ve všech kombinacích .....                    | 99  |
| Tabulka 22: Kruskal-Wallisův test pro region 4 .....  | 100 |
| Tabulka 23: Deskriptivní statistické údaje pro region 5 ve druhé sérii měření .....                 | 101 |
| Tabulka 24: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 5 .....                 | 103 |
| Tabulka 25: Dvouvýběrové charakteristiky pro region 5 ve všech kombinacích .....                    | 104 |
| Tabulka 26: Kruskal-Wallisův test pro region 5 .....  | 105 |
| Tabulka 27: Deskriptivní statistické údaje pro všechny časy v rámci jednoho regionu .....           | 106 |
| Tabulka 28: Deskriptivní statistické údaje pro všechny regiony v rámci jednoho časového úseku ..... | 107 |
| Tabulka 29: Deskriptivní statistické údaje pro region 1 v první sérii měření .....                  | 108 |
| Tabulka 30: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 1 .....                 | 110 |
| Tabulka 31: Dvouvýběrové charakteristiky pro region 1 ve všech kombinacích .....                    | 111 |
| Tabulka 32: Kruskal-Wallisův test pro region 1 .....  | 112 |
| Tabulka 33: Deskriptivní statistické údaje pro region 2 v první sérii měření .....                  | 113 |
| Tabulka 34: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 2 .....                 | 115 |
| Tabulka 35: Dvouvýběrové charakteristiky pro region 2 ve všech kombinacích .....                    | 116 |
| Tabulka 36: Kruskal-Wallisův test pro region 2 .....  | 117 |
| Tabulka 37: Deskriptivní statistické údaje pro region 3 v první sérii měření .....                  | 118 |
| Tabulka 38: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 3 .....                 | 120 |
| Tabulka 39: Dvouvýběrové charakteristiky pro region 3 ve všech kombinacích .....                    | 121 |
| Tabulka 40: Kruskal-Wallisův test pro region 3 .....  | 122 |
| Tabulka 41: Deskriptivní statistické údaje pro region 4 v první sérii měření .....                  | 123 |
| Tabulka 42: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 4 .....                 | 125 |

|   |     |
|---|-----|
| Tabulka 43: Dvouvýběrové charakteristiky pro region 4 ve všech kombinacích .....    | 126 |
| Tabulka 44: Kruskal-Wallisův test pro region 4 .....                                | 127 |
| Tabulka 45: Deskriptivní statistické údaje pro region 5 v první sérii měření .....  | 128 |
| Tabulka 46: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 5 ..... | 130 |
| Tabulka 47: Dvouvýběrové charakteristiky pro region 5 ve všech kombinacích .....    | 131 |
| Tabulka 48: Kruskal-Wallisův test pro region 5 .....                                | 132 |

## Úvod

Přírodní radioaktivita je zcela přirozeným jevem, vyskytujícím se na Zemi. Její vliv je zásadní, jelikož představuje nejvyšší ozáření obyvatelstva vůbec. Planeta Země se považuje za přirozeně radioaktivní, protože se v přírodě nachází více než tisíc radionuklidů. Ty vykazují samovolný rozpad, a tudíž jsou zdroji radioaktivního záření. Radionuklidy se vyskytují ve vodě, vzduchu, lidském těle či stavebních materiálech.

Je proto potřeba zaměřit se na vliv, jaký může mít ionizující záření na materiály a jejich degradaci. Významný degradační vliv by mohl zkreslit diagnostickou hodnotící úroveň a zanechat do obrazu artefakty. Myšlenkou práce je provedení série měření ke zjištění rozsahu poškození obrazu a vytvoření matematického algoritmu pro zhodnocení míry degradace obrazu. Obecným předpokladem pro získání reálného obrazu v RTG diagnostice, bez jakýchkoli artefaktů, je primárně nepoškozená skiagrafická kazeta. Poškození může být mechanické, ale také způsobené stopami ionizujícího záření. Práce zkoumá vliv ionizujícího záření, konkrétně přírodní radiace na kazety pro nepřímou digitalizaci.

V práci je využito kontinuálního měření na standardně užívané skiagrafické kazetě s užitím olovené gumy, jako vhodného markeru s vysokým absorpčním koeficientem. Guma je umístěna do středu kazety a po dobu různých expozičních časů se hodnotí, zdali i přírodní pozadí může mít na skiagrafickou kazetu vliv či nikoli.

Exponované kazety jsou poté prahovacími segmentačními metodami, konkrétně OTSU a Fuzzy, zpracovány. U těchto segmentačních metod se v první řadě hodnotí jejich vlastnosti matematickým zpracováním a následně i vizuální stránka po jejich aplikaci na těžko čitelné obrazy. Pro provedení segmentace je potřeba odseparovat jednotlivé jasové složky odpovídající příslušným regionům. Statistickou analýzou (deskriptivní statistické metody, dvouvýběrové testy, vícevýběrové testy) a tvorbou predikčních modelů jsme schopni vyhodnotit degradaci kazety v závislosti dávky na čase a zdali se opravdu jedná o přírodní radiaci nebo jiné vlivy, které by mohly kazetu degradovat.

# 1 Ionizující záření

Díky ionizujícímu záření dochází k emisi energie prostřednictvím vlnění či částic skrze prostor nebo hmotu. Je typem záření s vysoce energetickými kvanty, které umožňují vyrazet (přímo či nepřímo) elektrony z atomového obalu, díky čemuž dochází k ionizaci prostředí. Ionizace umožňuje tvorbu iontových párů (obsahují kladné i záporné ionty). [1][3]

## 1.1 Základní typy záření

Dělí se na pět typů dle rozdílných fyzikálních vlastností popsanych níže.

### 1.1.1 Záření alfa

Jedná se o proud helionů (2 kladně nabitých částic). Kvanta tohoto záření mají hmotnost  $6,656 \cdot 10^{-27}$  kg a jejich energie se pohybuje v rozmezí 4–9 MeV. Vnik částice  $\alpha$  do hmotného prostoru způsobí vytrhávání částic z atomového obalu. To je způsobeno působením elektrické síly na záporně nabitě částice, vyskytující se v hmotném prostředí. Jeho dolet je značně krátký, důvodem je rychlé zbrzdění ve hmotě, nicméně se vyznačuje vysokými ionizačními schopnostmi. Jako zářič alfa je považován radon, radium i uran. Záření alfa lze odstínit například kusem papíru.

Ztráta měrné energie lze vyjádřit vztahem (1.1):

$$-\frac{dE}{dx} = f(E) = g(v), \quad (1.1)$$

kde  $dE$  je změna energie [J, eV],  
 $dx$  změna dráhy [m],  
 $E$  okamžitá energie [J, eV],  
 $v$  okamžitá rychlost [m/s]. [1][2][3]

### 1.1.2 Záření beta

Je tvořeno rychlými elektrony ( $\beta^-$ ) nebo pozitrony ( $\beta^+$ ). Vyznačuje se značným energetickým rozsahem sahajícím až k hodnotám 16,6 MeV. Částice beta záření jsou relativně lehké  $9,1 \cdot 10^{-31}$  kg. Přírodní radionuklidy se vyskytují zřídka a emitují jen elektrony, zatímco umělé umožňují emisi jak elektronů, tak i pozitronů. Částice beta jsou pronikavější než částice záření alfa, nicméně pro odstínění dostačuje metrová vrstva vzduchu či milimetrová vrstva hliníku. K emisi elektronů dochází při neřízených přeměnách:

- $\beta^-$  – z neutronu na proton,
- elektronový záchyt – z protonu na neutron,
- $\beta^+$  – z protonu na neutron.

Beta záření vykazuje značné interakce s hmotou, řadí se zde elastický rozptyl, ionizace a brzdné záření. [1][2][3]



### 1.1.3 Záření gama a RTG

Gama je typem fotonového záření s krátkou vlnovou délkou a nulovou hmotností. Energie tohoto záření se pohybuje od 0,05 MeV po 5 MeV. Vznik gama záření se pojí s radioaktivními ději a jadernými a subjadernými reakcemi. Při průchodu hmotným prostředím dochází k fotoefektu, Comptonovu rozptylu a tvorbě elektron-pozitronových párů. [1][2][3]

Je také typem krátkovlnného fotonového záření s nulovou hmotností a energií od 10 keV po 200 keV. V medicínských aplikacích se využívá RTG záření s vlnovými délkami 5-100 pm. Energie fotonu (rovnice (1.2)) je definována jako:

$$E = hf = h \frac{c}{\lambda} [J, eV], \quad (1.2)$$

kde  $h$  je Planckova konstanta [Js],

$f$  frekvence záření [Hz],

$c$  rychlost světla [m/s],

$\lambda$  vlnová délka záření [m].

Mezi důležitá specifika rentgenového záření patří jeho vlnově-korpuskulární dualismus. Ten říká, že se záření může chovat jako vlna, tak i jako částice. Zdrojem je nejčastěji rentgenka, u níž dochází k interakcím mezi katodou a anodou, za vzniku brzdového a charakteristického záření. [1][2][3]

### 1.1.4 Neutronové záření

Neutronové záření je tvořeno nenabitými částicemi o hmotnosti  $1,674 \cdot 10^{-27}$ , vznikajícími při jaderných reakcích. Do nichž se řadí štěpení uranu či samovolné štěpení atomů. Energetické rozpětí je značně široké od hodnot menších než 0,002 eV až k hodnotám větším než 50 MeV. Částice mají neutrální náboj, tudíž nejsou schopny přímé ionizace. Nejdůležitějšími interakcemi pro neutronové záření je pružný rozptyl a radiační záchyt. [1][2][3]

## 1.2 Umělé zdroje ionizujícího záření

Mezi umělé zdroje radioaktivity se řadí všechny ty, které člověk nějakým způsobem vypouští do životního prostředí. Řadí se zde i radionuklidy, vznikající při spalování fosilních paliv, které by za normálních okolností bez lidského zásahu zůstaly pod zemským povrchem.

Největší ozáření pochází z lékařských zdrojů, u nichž se rozlišuje užití ionizujícího záření v diagnostice a radioterapii. Radiodiagnostika je specifická pro relativně nízké dávky za účelem zjištění možných lézí či patologií v lidském těle. Naopak radioterapie využívá vysokých dávek za účelem nádorové terapie či paliativní léčby. [1][2][3]

## 1.3 Přírodní zdroje ionizujícího záření

Ozáření, pocházející z přírodních zdrojů má dvě primární oblasti vzniku. První z nich je tzv. kosmické záření, dopadající z vesmíru na zemský povrch. Jeho účinek na člověka závisí na konkrétní oblasti a nadmořské výšce. Ekvivalentní dávka kosmického záření se pohybuje v rozmezí 0,25 až 0,30+ mSv ročně. Primární částice pocházejí ze Slunce a hlubokého vesmíru a srážejí se s atmosférou. Díky

této interakci dochází ke vzniku sekundárních částic. Jako ochrana před kosmickým zářením slouží magnetické pole s Van Allenovými pásy. Částice jsou zachycovány ve výškách do 50 000 km nad zemí a ostatní záření je odstíněno ozonovou vrstvou. I přes tento fakt dochází k ozáření obyvatelstva, a to především ve vyšších nadmořských výškách. [4][5][6]

Druhou jsou přírodní radionuklidy, vyskytující se volně v přírodě a lidském těle. Dle původu se dělí na:

### 1.3.1 Kosmogenní radionuklidy

Průběžně vznikají díky jaderným reakcím ve vnějším zemském obalu, při průchodu kosmického záření s vysokoenergetickou složkou. Řadí se zde zejména radiouhlík  $^{14}\text{C}$ , který je využíván především k radiometrickému stanovení stáří biologických objektů a tritium  $^3\text{H}$ . Mezi další radionuklidy, vyskytující se v nepatrném množství patří také  $^{32}\text{P}$ ,  $^{7,10}\text{Be}$  nebo  $^{35}\text{S}$ . [2][4][5][6]

### 1.3.2 Primordiální radionuklidy


Vykazují poměrně dlouhý poločas rozpadu (hodnoty nad  $10^8$  let), tudíž se stále vyskytují ve značném množství i přes to, že se jejich vznik pojí s ranými fázemi vzniku vesmíru. Vznik se pojí k termonukleárním reakcím v útrobách hvězd.

Nejrozšířenějším zástupcem je  $^{40}\text{K}$  draslík. Ten se zaujímá v procentuálním zastoupení půdy asi  $3 \cdot 10^{-3}$ . Draslík podléhá dvěma rozpadům – beta minus se rozpadá na  $^{40}\text{Ar}$  (argon), zaujímající 80 % a elektronovým zachytem na  $^{40}\text{Ca}$  (vápník), zaujímající 11%. Dalším zástupcem je  $^{232}\text{Th}$  (thorium), které podléhá alfa radioaktivitě a vše popisují thoriové rozpadové řady. Nejvýznamnějšími radionuklidy vůbec jsou  $^{238}\text{U}$ , zaujímá  $2\text{--}4 \cdot 10^{-6}$  a  $^{235}\text{U}$  s koncentrací  $2\text{--}3 \cdot 10^{-8}$ . Oba se prostřednictvím alfa rozpadu přemění na uranové rozpadové řady. [2][4][5][6]

### 1.3.3 Sekundární radionuklidy

Jsou produkty rozpadových řad primárních radionuklidů a v přírodě se setkáváme s uran-radiovou, aktiniovou a thoriovou. [2][4][5][6]

Přírodní zdroje tvoří nejčtenější skupinu v ozáření obyvatelstva, na rozdělení dávek poukazuje Obrázek 1.



Obrázek 1: Rozdělení dávek pro obyvatelstvo [upraveno z 5]

### 1.3.4 Radioaktivní rozpadové řady

Rozpad radionuklidů může buď vést rovnou ke stabilní konfiguraci nebo k rozpadu na další nestabilní jádro, které rovněž vykazuje radioaktivitu. V přírodě se vyskytují pouze tři, jak již bylo uvedeno výše. Velkou výhodou je fakt, že díky přeměnovým řadám lze určit vlastnosti radionuklidů i přes to, že se již nemusí vyskytovat.

Rozpadová řada se dá definovat jako řada izotopů, na které se postupně rozpadá ten izotop, který je umístěn jako první. Existují čtyři a jejich název je odvozen od izotopu, jehož poločas rozpadu je nejdelší.

Číslice 4, na začátku každé řady udává počet nukleonů v alfa částici. Ke změně hmotnostního čísla dochází pouze u alfa rozpadu. Písmenem A se označuje hmotnostní číslo a n je přirozené číslo.

1. Thoriová řada –  $A = 4n$ :  ${}^{232}_{90}\text{Th}, \dots, {}^{208}_{82}\text{Pb}$ .
2. Neptuniová řada –  $A = 4n + 1$ :  ${}^{237}_{93}\text{Np}, \dots, {}^{209}_{83}\text{Bi}$ .
3. Uranová řada –  $A = 4n + 2$ :  ${}^{238}_{92}\text{U}, \dots, {}^{206}_{82}\text{Pb}$ .
4. Aktiniová řada –  $A = 4n + 3$ :  ${}^{235}_{92}\text{U}, \dots, {}^{207}_{82}\text{Pb}$ .

Izotop, stojící na konci řady je stabilní a nepodléhá dalšímu rozpadu. Poločas rozpadu je pro každý prvek rozdílný a může se pohybovat od desítek minut po miliony let. [2][8]

## 1.4 Pozadí ionizujícího záření: obrazová perspektiva

Ionizující záření z přírodních zdrojů, známé také jako přírodní radiační pozadí, existuje na zemi od jejího vzniku. Slovo radiace v lidech většinou evokuje strach, jelikož lidské smysly nedokážou detekovat přítomnost radiačního záření. Uvedená studie zkoumala katalog obrázků zobrazujících distribuci radioaktivity v běžných předmětech a potravinách s použitím fotografického materiálu z kazety pro nepřímou digitalizaci. Cílem bylo pomocí vizuální demonstrace radioaktivity běžných předmětů a potravin prokázat radioaktivitu prostředí, ve kterém žijeme.

Radioaktivita byla v rámci uvedené studie sledována ve vzorcích stavebních materiálů, drahokamů, zeleniny, ovoce, cukrovinek a nápojů, a to s použitím fotografického materiálu z kazety pro nepřímou digitalizaci (Kodak GP). Aby nedošlo k poškození fotografického materiálu vlivem radiace, byl obalen plastovou folií. Vzorky uložené na tento materiál byly upevněny páskou a vloženy do stíněného boxu složeného z olověných desek o tloušťce 5 cm. Nejlepších výsledků bylo dosaženo po 20 dnech uložení vzorků v olověném stíněném boxu.

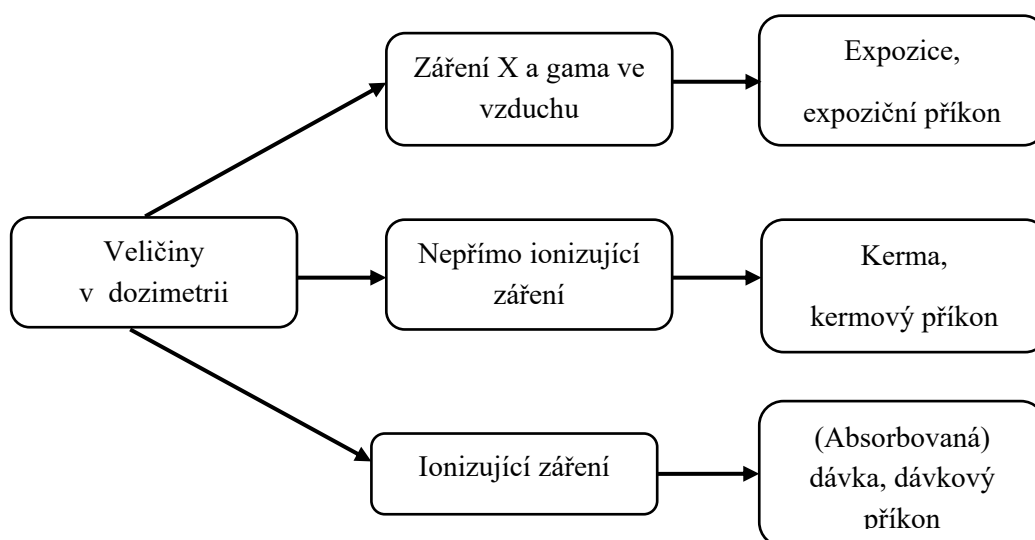
Bylo zjištěno, že stavební materiály obsahují velké množství přirozeně se vyskytujících radionuklidů, konkrétně uranu, thoria a radioizotopu draslíku. Zásadní částí studie bylo nicméně zkoumání radioaktivity potravin. Radioaktivní materiál vyskytující se v půdě a vodě je vstřebáván do lidského organismu prostřednictvím rostlin a zvířat, a to je důvodem, proč všechny potraviny, které konzumujeme, jsou mírně radioaktivní. Ze studie vyplynulo, že hlavní radionuklid naměřený ve vybraných vzorcích potravin byl nestabilní draslík.

Bylo potvrzeno, že některé potraviny obsahují více radioaktivity než jiné, a to z důvodu rozdílné koncentrace vybraných prvků. Mezi nejvíce radioaktivní potraviny se řadí například mořské plody, kakao či káva. Nejnižší radioaktivitu vykazovala cibule. Vliv na množství radionuklidů v potravinách se také odvíjí od lokální radioaktivity prostředí (půda, vzduch, voda, záření), ve kterém se dané potraviny pěstují či vyrábějí. Množství radioaktivity v potravinách je nicméně malé a není pro lidský organismus škodlivé. [14]

## 2 Základní veličiny v dozimetrii

Obecně se veličiny a jednotky užívané v radiační fyzice dělí na čtyři základní skupiny. Na ty, které popisují zdroj záření, dále pole záření, látku, na kterou záření působí a samozřejmě na člověka. Veličiny, které se sledují v dozimetrii jsou rozděleny na Obrázku 2. [3][10]

### 2.1 Expozice a expoziční příkon



Obrázek 2: Veličiny v dozimetrii [10]

Expozice  $X$  vyjadřuje množství ionizujícího záření, které prošlo bodem v prostoru. Je definována pouze pro fotonové záření a jeho účinky ve vzduchu, a proto jim lze přímo měřit. Využívá se pro kalibraci, standardizaci apod. Doporučenou jednotkou pro dozimetrii je v dnešní době místo expozice kerma. Jednotkami jsou (C/kg) coulomb na kilogram a dřívější (R) roentgen. Je definována jako rovnice (2.1):

$$X = \frac{dQ}{dm} \left[ \frac{\text{C}}{\text{kg}} \right], \quad (2.1)$$

kde  $dQ$  je celkovou absolutní hodnotou elektrického náboje iontů [C],  
 $dm$  je hmotnost látky [kg].

Expozičním příkonem (2.2) rozumíme přírůstek expozice  $dX$  v časovém intervalu  $dt$ :

$$X = \frac{dX}{dt} \left[ \frac{\text{C}}{\text{kgs}} \right]. \quad (2.2)$$

Jednotkou je coulomb na kilogram za sekundu (C/kgs). [2][3][10]

## 2.2 Kerma a kermový příkon

Jak ukazuje Obrázek 2, kerma je vztažena jako veličina k nepřímo ionizujícímu záření (neutrony, gama záření). Pokud jsou částice v rovnovážném vztahu odpovídá kerma, číselně, absorbované dávce. Charakterizuje energii nepřímo ionizujícího záření v dané látce. Jednotkou je gray (Gy) neboli J/kg. Definice (2.3) je následující:

$$K = \frac{dE_K}{dm} \text{ [Gy]}, \quad (2.3)$$

kde  $dE_K$  je součet všech počátečních energií (kinetických) nabitých částic, které jsou uvolněny nenabitými částicemi v objemu látky [J],  
 $dm$  je hmotnost látky [kg].

Kermový příkon (2.4) definuje přírůstek kermy  $dK$  za čas  $dt$ :

$$K = \frac{dK}{dt} \left[ \frac{\text{Gy}}{\text{s}} \right]. \quad (2.4)$$

Jednotkou je Gy/s. [2][3][10]

## 2.3 Absorbovaná dávka a dávkový příkon

Je základní veličinou pro dozimetrii, je definována jako energie záření absorbovaná v 1 kilogramu látky. Jednotkou je gray (Gy). Jedná se o obecnou veličinu, hodnotící účinky přímo ionizujícího záření. Je definována (2.5):

$$D = \frac{dE}{dm} \text{ [Gy]}, \quad (2.5)$$

kde  $dE$  je střední energie [J],  
 $dm$  je hmotnost látky [kg].

Dávkový příkon je dobře interpretovatelnou a zároveň i měřitelnou veličinou, proto se s ním setkáváme ve většině (až 80 %) monitorovacích zařízeních. Její zavedení informuje o vztahu biologických účinků nejen k dávce, ale i k času. Rovnice (2.6) vypadá následovně:

$$D = \frac{dD}{dt} \left[ \frac{\text{Gy}}{\text{s}} \text{ resp. } \frac{\text{Sv}}{\text{s}} \right], \quad (2.6)$$

kde  $dD$  je přírůstek dávky [Gy],  
 $dt$  je časový interval [s].

Základní jednotkou je Gy/s, avšak v praxi se využívají mGy/h či  $\mu\text{Gy/h}$ . [2][3][10]

### 3 Degradace materiálů vlivem radiace

Každé záření působí na materiály s jinou intenzitou, dobou účinku i jinými specifickými vlastnostmi, tudíž je výsledek pro každý typ rozdílný.

#### 3.1 Radiační poškození

Interakce mřížkových atomů (n) umožňuje tři typy poškození:

1. **vyražení atomů z původních mřížkových pozic** – dojde k poruchám krystalové mřížky a nastávají například bodové poruchy při neobsazenosti polohy v mřížce (vakance), či se může uvolnit místo mimo mřížku (intersticiální poloha částice),
2. **excitace elektronů**, vedoucí k ionizaci atomu,
3. **změna chemické struktury** – způsobena zachytem mřížkových atomů a transmutací (jadernou reakcí dochází k umělé či přirozené změně chemických prvků na prvky jiné), řadí se zde:
  - B, Li, Be → He (s vysokou energií, vznik dalších srážek),
  - U, Pu → inertní plyn (zvýšení objemu, nerozpustnost, praskání). [2][9]

Mřížkové atomy podléhají dvěma typům srážek:

##### 3.1.1 Pružné (elastické) srážky

Tento typ srážky definuje vztah (3.1) pro kinetickou energii  $T$ , kterou dopadající atom předá atomu mřížkovému:

$$T = \frac{4Mm}{(M+m)^2} E \sin^2 \left( \frac{\theta}{2} \right) \text{ [J]}, \quad (3.1)$$

kde  $M$  je hmotnost atomu [kg],  
 $m$  hmotnost dopadající částice [kg],  
 $\theta$  úhel rozptylu ( $\theta = 180^\circ =$  dopředný rozptyl)  $[\circ]$ ,  
 $E$  celková energie dopadající částice [J]. [2][9]

##### 3.1.2 Nepružné (inelastické) srážky

Druhým typem srážek jsou nepružné, definuje je celková energie částice (3.2), jejíž dopadající část se změní na tepelnou (tzn. jiný typ záření):

$$E = T + E' + Q \text{ [J]}, \quad (3.2)$$

kde  $T$  je kinetická energie mřížkového atomu [J],  
 $E'$  kinetická energie částice po srážce [J],  
 $Q$  ztráta energie [J]. [2][9]

### 3.2 Vliv záření na materiály

Samotné účinky záření závisí na několika faktorech, které se vzájemně ovlivňují a někdy i nepatrná změna jednoho z nich může vyvolat významné radiační poškození:

- druh a energie záření,
- dávka a spektrum záření,
- ozařovaný materiál
  - druh vazby – keramika, polymer, kov, ...
  - typ atomů – účinný průřez pro zachyt, rozptyl, štěpení,
  - struktura materiálu.
- podmínkách při měření – čas, objem, apod...

Záření alfa, které je specifické krátkým doletem dochází k poškození pouze u materiálů, ve kterých vzniká.

Beta záření s nízkou hmotností částic má pouze malé účinky na kovové materiály.

Naopak záření gama je schopno prostupovat i skrze tlustější materiály a interagovat s elektronovým obalem, a tak látku ionizovat.

U alfa, beta i gama záření nastávají významné změny u materiálů s kovalentní vazbou např. plastů, kde dochází k rozpadu makromolekul (tzv. depolymeraci), následné absorpci vody a vzniku plynů. Výsledkem je snížení mechanických vlastností. Naopak u kovů je účinek nevýznamný.

U neutronového záření je poškození až 1000x vyšší než u záření alfa, beta či gama. Dochází zde k poškození krystalických struktur a vzniku jaderných reakcí a vyražení atomů. [2][9]

### 3.3 Citlivost kazet pro nepřímou digitalizaci obrazu na přírodní radiační pozadí

Problematicke ionizujícího záření a jeho působení na kazety pro nepřímou digitalizaci se věnuje bakalářská práce, vytvořená na Ostravské Univerzitě [15]. Autorka řešila problematiku působení přírodního radiačního pozadí v závislosti na čase. Srovnávala obrazová data přenesená do histogramů s dávkami, naměřenými dozimetrem.

Pro měření se využily kazety Kodak PQ Storage Phosphor Screen o rozměrech 35x43 cm a dozimetr DMC 300. Základem experimentu bylo vytvoření referenčního obrazu, kdy byla kazeta vymazána a následně okamžitě vyvolána. Údaje z dozimetru byly rovněž nulovány. Tím byl získán nulový čas, a tudíž i výchozí bod práce. Pro samotné měření byl na kazetu umístěn marker – kus olovnaté gumy s rozměry 5x5 cm, jelikož vykazoval nejvhodnější absorpční vlastnosti. Byl umístěn do středu kazety, aby autorka mohla lépe vytvořit a vyhodnotit histogramy. Při měření byl vedle kazety umístěn dozimetr, který po celou dobu probíhajícího měření zaznamenával hodnoty radiačního pozadí. Podmínky pro měření se neměnily a měření se provádělo vždy kolem 7 hodiny ránní v periodických intervalech.

Po proběhlých měřeních autorka vynesla jasová data do histogramů. U prvního zmíněného měření, tzv. referenčního obrazu, vykazovala kazeta neúplnou bílou barvu, vyskytovaly se zde i známky



barvy černé. Z čehož bylo usouzeno že přírodní radiace působí na okolí v určité míře neustále. S rostoucím časem bylo možno pozorovat rostoucí zastoupení černé barvy, zatímco bílá barva vykazovala pokles. K nejvyššímu relativnímu pohybu vrcholů u histogramů došlo v rámci 24 hodin a to o 33,2 %. Naopak nejmenší rozdíl nastal mezi 24 a 48 hodinami, o pouhých 0,8 %.

Z naměřených dávek v závislosti na čase byla zjištěna určitá nelinearita v působnosti přírodního pozadí. Vše se ověřovalo srovnáním naměřených dávek s dávkami teoretickými. Nejvyšší relativní rozdíl mezi naměřenými a teoretickými hodnotami byl v rámci prvního dne, kdy byla skutečná dávka o 53,62% vyšší než teoretická hodnota. U čtvrtého a osmého dne byl rozdíl nejmenší, pouze 4,35 %. Lze soudit, že na kazetu působí i další vlivy, jako tlak, teplota, či nadmořská výška, avšak radiační pozadí vykazuje neustálou aktivitu při působení, kterou práce potvrdila. Práce zkoumala problematiku z pohledu radiologických asistentů, u nichž je potřeba klást důraz na kvalitu skiagrafičtých snímků.

Autorka subjektivně hodnotila posun jasových úrovní vzhledem k závislosti na délce expozice pomocí základního typu histogramů s vnesenými procentuálními hodnotami. Dále provedla srovnání relativních hodnot umístění vrcholů, závislost dávek z přírodního radiačního pozadí na čase a v poslední řadě zhodnotila relativní rozdíl mezi teoretickými a skutečnými dávkami. [15]

### **3.4 Vliv ionizujícího záření na vlastnosti polymerů**

V disertační práci [16] byly sledovány změny vlastností pro polymery při změnách mechanických vlastností. U obou materiálů je to napětí na mezi kluzu (MPa), tažnost (5), e-modul pružnosti v tahu (MPa) a tvrdost podle ShoreD. Sledoval se vliv širokého spektra dávek záření beta na volně dostupném polyetylenu. Zařízení, které se využívalo je v praxi běžně využíváno. Autor předpokládal, že by výsledky práce mohly mít využitelné části i pro průmysl v oblasti zpracování polymerů při rozhodování o volbě dávky působící na materiál.

Po konzultaci s výrobcem byly zvoleny polymery vhodné pro radiační sítování. Vstřikováním se připravila zkušební tělesa tak, aby byly dodrženy všechny potřebné technologické podmínky. Urychlenými elektrony se tělesa ozařovala a využilo se širokého spektra dávek. Následně byly provedeny mechanické zkoušky v tahu, dále rázové houževnatosti při změnách teploty a také tepelné zkoušky DSC a TMA. Na zkušebních vzorcích se provedla RTG difrakce, která měla za úkol popsat strukturální změny vlivem ozáření. Byly vybrány materiály LDPE (DOW LDPE 780 E) – Low Density Polyethylene, tzn. polyethylen s nízkou hustotou, HDPE (DOW HDPE 25055 E) – High Density Polyethylene, tj. polyethylen s vysokou hustotou. Výsledky byly testovány na odlehle hodnoty, testem normality a teorií hypotéz se stanovila statistická významnost naměřených hodnot.

Analyzované výsledky potvrdily fakt, že beta záření způsobilo změnu mechanických vlastností pro materiály HDPE a LDPE. Vlastnosti vykazovaly patrné výchylky při změnách dávky i teploty. Z naměřených dat byly odstraněny odlehle hodnoty a testem normality (Anderson-Ling), dále teorií hypotéz určeny hladiny významnosti. Byla vytvořena tzv. matice vlastností, reprezentující pokles/nárůst pozorovaných veličin vzhledem k měnícím se dávkám ionizujícího záření. Z měření vyplynulo, že se zvyšující se dávkou záření se mez pevnosti i modul pružnosti v tahu také zvyšují. Naopak poměrné prodloužení klesá, a to až pod hodnotu materiálů, které ozářeny nejsou. Rozdílné vlastnosti vykazoval při vyšších teplotách pouze LDPE, kde poměrné prodloužení naopak rostlo, HDPE nedocházelo u tohoto parametru k výrazným změnám. Největší změny vykazovaly jak DEPE, tak LDPE při dávce 132 kGy.

Tuto dávku bylo potřeba zvážit vzhledem k efektivitě procesu. U některých případů totiž bylo možno volit dávku nižší se stejnými výsledky. U rázových vlastností vzrostla vrubová houževnatost daných materiálů. Houževnatostí se označuje schopnost materiálu absorbovat mechanickou energii, vrubovou houževnatostí se definuje dynamická zkouška rázu na kyvadlovém kladivu, tzv. Charpyho kladivu. U HDPE došlo k nejvyššímu nárůstu při hodnotách 198 kGy u pokojové teploty, při zvýšené teplotě u hodnoty 165 kGy. U LDPE byl nejvyšší nárůst zaznamenán u hodnoty 66 kGy, při rostoucích dávkách hodnoty naopak klesaly. Autor také zkoumá tvrdost materiálu s rostoucí dávkou, kdy nejvyšší nárůst tvrdosti u HDPE byl při dávce 99 kGy, u LDPE 132 kGy.

Z výsledků autor usoudil, že při rostoucí dávce ionizujícího záření došlo u obou materiálů k poklesu teploty krystalizace a teploty tání. Nicméně oba materiály vykazovaly po ozáření vyšší teplotní odolnost, což vyplynulo z provedené termochemické analýzy. Autor také poukazuje na fakt, že je potřeba dávky optimalizovat tak, aby přidaná hodnota modifikace pro konečný produkt byla co možná nejlepší. [16]

### **3.5 Modelování a analýza efektu ionizujícího záření na paměťových fóliích**

V práci [17] se autorka zabývá obdobnou tematikou, která se řeší v této diplomové práci, tzn. vlivem ionizujícího záření na degradaci kazet pro nepřímou digitalizaci. Autorka v práci zkoumá vliv primárního ionizujícího záření od umělých zdrojů. Bylo provedeno měření s časovým odstupem 5 měsíců a prostřednictvím histogramů, lokálních minim a maxim byly zhodnoceny rozdíly v závislosti na počtu snímků a sériích. Výsledky autorka hodnotila statisticky a pomocí predikčních a aproximačních modelů.

Stěžejním cílem bylo zhodnocení míry degradace v závislosti na počtu opakování snímacích cyklů. Stanovil se design a realizovaly se experimentální měření. Všechny snímky byly provedeny s konstantním nastavením přístroje a pracoviště. Expozice byla uskutečněna 10x na 6 různých skiagrafických kazetách, a to ve dvou sériích (říjen a březen). Byl hodnocen jak primární svazek, tak pro další oblasti intenzity šedi sekundární sledovaná oblast s pryžovým plátkem.

Z vizuálního posouzení aproximačních výsledků byly patrné změny mezi 1. a 2. sérií, následně se zhodnocení provedlo i výpočetně. Byly vytvořeny rovněž modely pro hodnocení míry degradace v rámci 5měsíčního časového rozmezí. Predikční modely demonstrovaly průběhy parametrů v závislosti na čísle série a počtu cyklů. Díky nim lze očekávat nárůst stupňů šedi u zkoumaných kazet v průběhu měsíců.

Byla provedena statistická analýza výsledků, a byly vyneseny grafické závislosti. Rozdíly, které byly v práci hodnoceny se statistickými výpočty jeví jako statisticky významné. Díky této informaci mohla autorka soudit, že vliv ionizujícího záření má vliv na degradaci materiálů. Autorka sama navrhuje práci jako možnost pro další zkoumání, jelikož práce na podobné téma nejsou časté a v klinické práci se stále užívá nepřímé digitalizace, a tudíž i kazet. [17]

### 3.6 Vliv sekundárního rentgenového záření na kvalitu skiagrafických snímků

Práce [18] zkoumala degradaci skiagrafických kazet v závislosti na vzdálenosti zdroje záření, následně autorka tvořila matematický model umožňující predikci této degradace. V práci se řešil vliv sekundárního ionizujícího záření při snímání pacienta prostřednictvím mobilního a fixního RTG přístroje. Snímky jsou vyhodnoceny ve stupních šedi, charakterizujících sekundární ionizaci. Data jsou statisticky vyhodnocena a autorka se snaží určit optimální vzdálenost pro snímání.

Při experimentech bylo zjištěno, že mobilní RTG přístroj vykazuje vyšší míru sekundární ionizace než přístroj fixní. Optimální vzdálenost při expozičních hodnotách 77 kV a 11 mAs byla u fixního přístroje vyhodnocena na 2,72 m, u mobilního 3,13 m. Proto je poměrně důležitá spolupráce s radiologickým asistentem a je potřeba, aby při užívání mobilních přístrojů, produkujících ionizující záření, byly osoby v dostatečné vzdálenosti od zdroje.


Druhá část experimentu zkoumala uniformitu paměťových fólií, kdy se vycházelo z předpokladu, že výrobce kazety označoval jako zcela identické. Z výsledků bylo patrné, že každá kazeta měla rozdílnou senzitivitu, nicméně výsledky se nedají považovat za stěžejní, jelikož bylo měření provedeno pouze v krátkém časovém úseku. Sekundární ionizující záření se v praxi pro zobrazování neužívá, jedná se pouze o chybu zapříčiněnou lidským faktorem.

Dvě různé kazety vykazovaly odlišné stupně šedi, mohlo to být způsobeno několika faktory. Jedním z nich je časový faktor. Jelikož se doba mezi expozicemi lišila, a tudíž na obě kazety působily i jiné faktory (např. přírodní pozadí apod.). Druhým možným důvodem byl rozdílný rok výroby a možná změna složení kazety.

Autorka navrhuje pokračování v tématu práce z hlediska optimální vzdálenosti pro dolní a horní mez intenzity šedi, intenzita šedi maximálního peaku z čehož je možno zrekonstruovat Gaussovu křivku. Dále autorka uvažovala, jestli by byla možná zpětná rekonstrukce obrazu sekundárního záření z křivky v optimální vzdálenosti kazety pro skiagrafii od zdroje ionizujícího záření. [18]

## 4 Radiometrická měřicí technika

Princip radiometrické přístrojové techniky se zakládá na vlastnostech, které jsou specifické pro ionizující záření a zároveň na interakci tohoto záření v hmotném prostředí. Vstupní částí přístroje je detektor, který převádí záření na měřitelnou odezvu (signál). Následné zpracování a vyhodnocení signálu probíhá v měřicím přístroji. Blokové schéma radiometrické měřicí techniky je uvedeno na Obrázku 3. [3][13]



Obrázek 3: Blokové schéma radiometrické aparatury [3]

Rozdělení detektorů ionizujícího záření lze provést dle různých hledisek. Jedno z nich je rozdělení na integrální a kontinuální detektory. U kontinuálních detektorů dostáváme průběžnou informaci o hodnotě měřené veličiny. Po ukončení ozařování, dojde u vstupního signálu k poklesu na nulu. Využití nalezneme u monitorování havárií, či radiačních nehod. Kdežto u integrálního detektoru se hodnota signálu zvyšuje po dobu, po kterou je detektor vystaven záření. Po ukončení ozařování je informace o záření v detektoru trvale uchována. Uplatnění pro integrální detektory je v osobní dozimetrii, v radiační chemii či lékařství. [3][11][12][13]

Další rozdělení lze uskutečnit dle účelu měření. Zde se řadí radiometry, pomocí nichž lze v daném prostoru stanovit úroveň radioaktivity. Dále spektrometry, které z ionizujícího záření měří energii, a nakonec průmyslové radiometrické přístroje, využívající radionuklidy v průmyslu. [3][11][12]

Nejpoužívanější detektory lze rozdělit do tří skupin na základě principu detekce.

1. **Elektrické detektory** – látky na základě záření mění určité elektrické vlastnosti. Patří zde Geiger-Müllerovy počítače, ionizační komory a polovodičové detektory.
2. **Scintilační detektory** – dostáváme luminiscenční záření díky působení záření ionizujícího. Tento světelný signál se dále převádí na elektrický pro následné zpracování.
3. **Samostatné detektory** – látky pod vlivem ionizujícího záření mění dlouhodobě své vlastnosti (objem, barvu, složení). Jedná se o integrální detektory. [3][13]

### 4.1 Elektrické detektory

Za elektrické detektory se považují různě upravené deskové, nebo válcové kondenzátory. Proud prochází obvodem díky elektrickému zdroji připojenému k elektrodám kondenzátoru. Pokud připojíme zdroj záření mezi elektrody, můžou mezi deskami probíhat následující pochody:

- A. **Ionizace** – ionizační proud vzniká díky iontům, pohybujícím se k elektrodám, které jsou opačně nabitý.
- B. **Rekombinace** – molekula, nebo atom vniká při styku záporného a kladného iontu. Čím vyšší je napětí na kondenzátoru, tím je vyšší rychlost iontu a tím také klesá pravděpodobnost styku iontu.

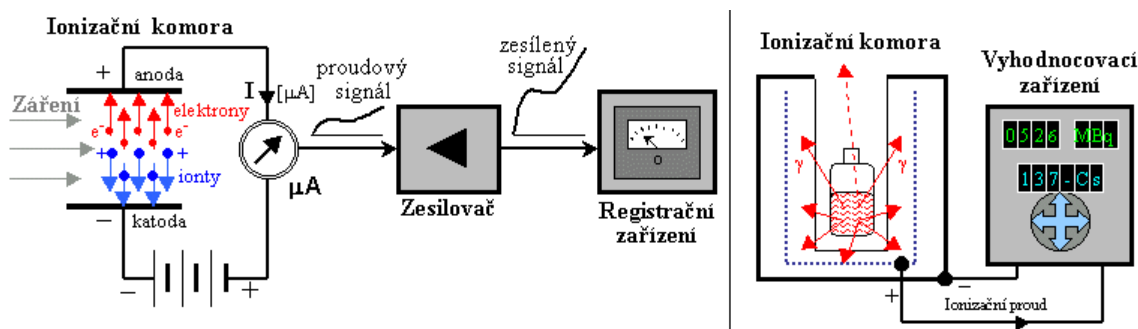
- C. **Přídavná ionizace** – Pokud ionty urychlíme na větší energii, než je energie plynu nacházejícím se mezi destičkami v kondenzátoru, můžou se vytvářet další ionty díky nárazové ionizaci. [3][13]

#### 4.1.1 Ionizační komory

Nejčastěji se jedná o válcové kondenzátory, na kterých nalezneme anodu a katodu v plynové náplni. Napětí se volí mezi 150–200 V. Tím pádem pracuje ionizační komora v oboru nasyceného proudu. K elektrodám komory se díky iontům přivádí ionizační záření. Tím se získá krátký napěťový impuls, nebo ionizační proud na vnějším obvodu. Schéma ionizační komory je na Obrázku 4.

Ionizačními komorami lze měřit alfa i beta zářiče. Také je možnost komoru opatřit vstupním oknem, přičemž absorpční koeficient materiálu musí být nízký. Gama záření se využívá v komorách, které využívají sekundární ionizace. Ionizační proud můžeme zaregistrovat i bez vystavení komory ionizačnímu záření. Tento proud se považuje za pozadí komory a způsobuje ho kosmické záření, vlhkost, nečistota, kontaminace komory či radioaktivita materiálu.


Ionizační komory se využívají v dozimetrii pro stanovení expozice, dávek a kermu obsažené ve vzduchu. Jako jediné mohou být využity v provozech, kde se nacházejí vysoké teploty (hutě, válcovny ap.). [3][13]



Obrázek 4: Schéma ionizační komory [13]

#### 4.1.2 Geiger-Müllerovy počítače

Mají trubicovitý tvar a plášť je z umělé hmoty nebo kovu. Tenký plátek, který se nachází napnutý ve středu trubice tvoří anodu. Katoda je tvořena válcem. Dochází k lavinovitému narůstání iontů díky vlivu sekundární ionizace a k samovolnému výboji v celém počítači při průchodu každé částice. To vyvolá napěťový impuls, který se dále zpracovává. Tento výboj je potřeba co nejdříve zastavit, protože během výboje neregistruje počítač žádné další částice, v praxi se to řeší vhodnou plynovou náplní. Na Obrázku 5 vidíme schéma G-M počítače a jeho reálný vzhled. Podle typu detekovaných částic rozdělujeme počítače na válcové, průtokové, zvonkové, okénkové, kyvetové apod. [3][13]

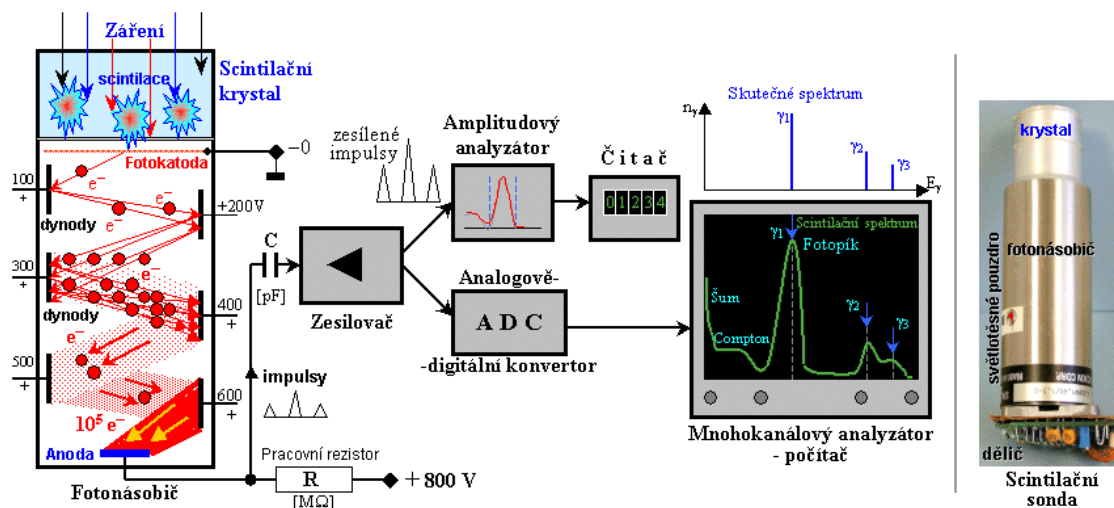


Obrázek 5: Schéma G-M počítáče [13]

## 4.2 Scintilační detektory

Scintilace je jev, kdy ionizující záření dopadá na určité látky, přičemž se v nich vyvolávají slabé světelné záblesky. Látky mohou být kapalné, plastické, organické, či anorganické. Scintilační počítač je pak sestaven ze scintilátoru, registračního zařízení a fotonásobiče.

Záření dopadá na scintilátor, ve kterém se vyvolá scintilace. Scintilátor se obklopuje reflektorem, neboť směr fotonů je náhodný. Reflektor odráží fotony zpět do krystalu. Ty poté dopadají přes optický kontakt na fotokatodu fotonásobiče a dochází k uvolnění elektronů, které se urychlí přes elektrické pole a dostanou se na dynodu. Na dynodě se počet elektronů výrazně zvýší a dále dopadají na anodu. Nakonec vzniká napěťový impuls na připojeném zátěžovém odporu a ten se zaznamenává v registračním bloku. Hlavní využití scintilačních počítačů je ve spektrometrech. Schéma detektoru uvádí Obrázek 6. [3][13]



Obrázek 6: Schéma scintilačního detektoru [13]

## 4.3 Filmové dozimetry

Fungují na principu vzniku latentního obrazu ve fotografickém materiálu díky působení ionizujícího záření. Obraz lze následným vyvoláním zviditelnit. Používají se převážně pro detekci gama, beta a RTG záření.

K výhodám patří vysoká citlivost, nízká cena, trvalost záznamu, možnost výpočtu dávek a automatizace odečtu optických hustot. Mezi nevýhodami najdeme malou přesnost, zdlouhavé vyhodnocování, směrovou závislost, poměrně vysokou citlivost na určité vnější vlivy jako je teplota, vlhkost, či chemické látky. Filmové dozimetry se řadí mezi integrální detektory. [3][13]

#### 4.4 Termoluminiscenční dozimetry

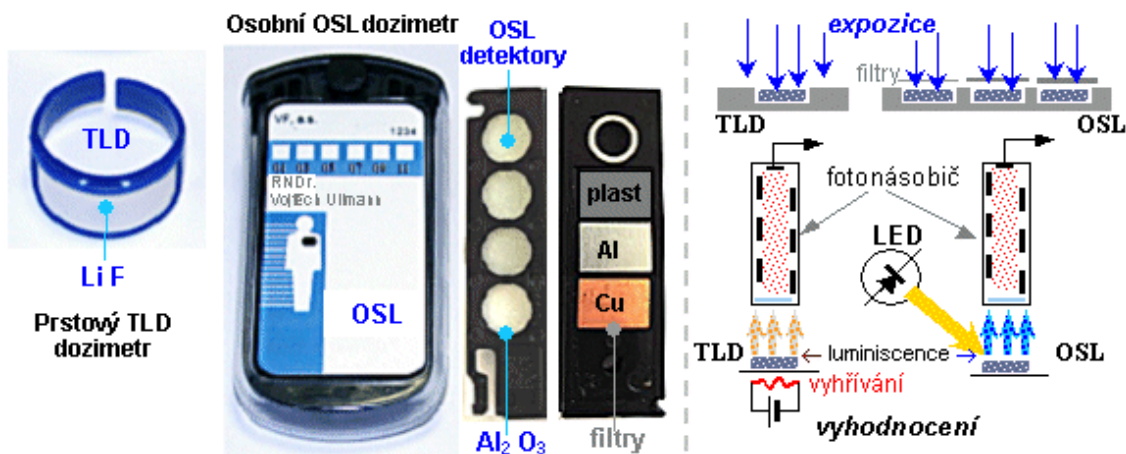
Při ozáření pevných dielektrických látek se zachytávají uvolněné elektrony do děr v elektronové pasti (lokální poruchy mřížky). Aby mohli opustit past, je zapotřebí dodat energii z vnějšku, například ohřevem látky (nejčastěji fluorid vápenatý), přičemž se část uvolněné energie vyzáří ve formě ultrafialového, nebo viditelného světla. Tomuto jevu se říká termoluminiscence.

V přístroji je zapouzdřena termoluminiscenční látka, která je vystavena záření. Poté se látka vyjme z pouzdra a vloží se do vyhodnocovacího zařízení. Tam je zahřáta na teplotu kolem 160-300°C. Následně se snímá ultrafialové, nebo viditelné záření pomocí fotonásobiče. Vyhřívací křivka je pak závislost elektrického signálu z fotonásobiče na teplotě. Schéma a dozimetr jsou uvedeny na Obrázku 7.

Mezi výhody patří malé rozměry a velký rozsah dávek. Nevýhodou je nákladné vyhodnocování. Termoluminiscence patří mezi nejrozšířenější metodu v rámci integrální dozimetrie. [3][13]

#### 4.5 OSL dozimetry

OSL = Opticky stimulovaná luminiscence, Obrázek 7. Princip je podobný jako u termoluminiscenčních dozimetrů, jen k uvolnění elektronů se používá ozáření viditelným světlem, namísto zahřátím pevných látek. A pro vyhodnocování se využívá ozáření LED diodou. OSL dozimetry mají dostatečnou přesnost a citlivost. Velikou výhodou je možnost opakovaného použití materiálu. Využití nalezneme převážně v osobní dozimetrii. [3][13]



Obrázek 7: Termoluminiscenční dozimetry, OSL dozimetry, schéma principu [13]

## 5 Digitální radiografie a záření X


Zobrazování rentgenovým zářením se stále řadí mezi primární a nejpřínosnější v oblasti diagnostiky. Jeho základem je rentgenka, detekční mechanismy a systémy pro zpracování. [11][13]

### 5.1 Digitální radiografie

Je běžnou metodou, využívanou v radiodiagnostice, která zahrnuje detektory pro výpočetní (či nepřímou) radiografii a radiografii přímou.

### 5.2 Nepřímá radiografie

Computed radiography či CR využívá ke svému zpracování paměťové fólie. Stěžejní je citlivá neboli luminiscenční vrstva, obsahující europium  $\text{BaFCl:Eu}^2$ . Po dopadu záření dojde k vybuzení a uvolnění elektronů. Elektrony jsou dále zachycovány tzv. elektronovými pastmi (metastabilní hladiny). Díky tomu vznikne latentní obraz, ten je dále přečten speciální čtečkou prostřednictvím fotostimulace červeným laserem. Parametry laserového světla jsou voleny tak, aby byly spektrálně odlišné od spektra emisního pro film. Dojde k uvolnění elektronů z elektronové pasti do vodivostního pásu, zároveň dochází k emisi fotonů. Fotony je možno registrovat prostřednictvím citlivého fotonásobiče a A/D převodníkem převést do digitální podoby. Intenzivním světlem lze obraz vymazat. Jednotlivé vrstvy paměťové fólie popisuje Obrázek 8. [11][13]



Obrázek 8: Struktura paměťové fólie [11]

### 5.3 Přímá radiografie

Přímá radiografie neboli detekce pomocí flat panelů je specifická velkým počtem detekčních prvků sestavených do matice nejčastěji 2000x2000 (i více). Intenzita záření, dopadající na matici, je přímo úměrná velikosti elektrického signálu. Výsledný signál je vyčten thin-film tranzistorovou maticí a A/D převodníkem převeden do PC pro další zpracování. Tranzistorová matice funguje pouze při čtení informace, čímž umožňuje náboji pohyb mezi fotonásobičem (fotodiodou) a zesilovačem během ozařování je tranzistor nevodivý. [3][11][13]



Existují dva základní typy flat panelů:

- **S přímou konverzí** – vrstva amorfního selenu (a-Se) umožňuje přímý převod fotonů na náboj. Tento typ konverze umožňuje značné obrazové rozlišení, neboť je možné vytvořit malé zobrazovací pixely. Zatím nejsou v praxi příliš využívány.
- **S nepřímou konverzí** – primární je měděná vrstva, umožňující prudký nárůst dávky, dále vrstva scintilační látky (jodid cesný), kde dochází ke vzniku světelných záblesků. Záblesky jsou zachycovány polovodičovými diodami, v nichž dojde k uvolnění náboje. Polovodičové diody jsou nejčastěji tvořeny vrstvou amorfního křemíku (a-Si). V dnešní době jsou nejpoužívanějším typem detekčních mechanismů. [3][11][13]

## 5.4 Rentgenka a vznik RTG záření

Zdrojem záření pro rentgenové zobrazování je rentgenka, vakuová elektronka, zapojená do vysokonapěťového obvodu (20-200 kV). Žhavicí transformátor umožní emisi elektronů z katody. Elektrony jsou díky silnému elektrickému poli urychlovány a dopadají na anodu. Na anodě dojde k prudkému zabrzdění elektronů, kde se část energie přemění na teplo (asi 99 %) a část na RTG záření.

Rentgenové záření může být dvojího druhu:

- **Brzdné záření** – dochází k zabrzdění elektronu v silném elektrostatickém poli u jádra a k zakřivení jeho dráhy. Jako přebytečná kinetická energie se vyzáří se foton RTG záření.
- **Charakteristické záření** – stěžejní je materiál anody, při dopadu na anodový povrch dojde buď k ionizaci nebo k excitaci. Při ionizaci jsou elektrony vyraženy přímo z atomového obalu a místo po vyraženém elektronu zaplní elektron z vyšší energetické hladiny. Při excitaci je elektron vyražen do vyšší energetické hladiny a následně se vrací zpět do nevybuzeného stavu. Přebytek energie se vyzáří ve formě charakteristického záření. [3][11][13]

## 6 Segmentační techniky pro zpracování obrazu

Hlavním důvodem, proč se medicínské obrazy zpracovávají je jejich lepší posouzení z hlediska informace, které nesou, jak z pohledu vizuálního, tak matematického. Především se obrazové zpracování zaměřuje na extrakci informací, které nejsou jednoznačně viditelné. Než se obraz začne zpracovávat, je nutné jeho předzpracování. Předzpracování zahrnuje operace jako odstranění šumu, rotaci, úpravu jasu či zmenšení. Segmentace je v rámci této práce realizována prostřednictvím prahování, a to konkrétně metodami OTSU a Fuzzy.

Samotnou segmentací se rozumí dělení obrazu na celky, které nemají společný prvek, ale jsou homogenní z hlediska obrazových vlastností (např. struktura nebo intenzita). Jednotlivé metody jsou popsány níže.

### 6.1 Statistické metody

Statistické metody zahrnují prahování, adaptivní prahování, Clustering, Kohonenovy mapy a MRF (Markov Random Fields).


#### 6.1.1 Prahování

Tresholding neboli prahování je metodou převodu obrazu do binární podoby dle distribuce úrovní šedi. Pro bližší vyhodnocení se užívá histogram, který reprezentuje jednotlivé informace o počtu pixelů v obraze dle úrovní šedi. Na základě analýzy histogramu se určí práh  $T$  (threshold), dle něž je obraz rozdělen na požadovaný počet regionů. Proces segmentace je následně prováděn dle definovaných prahů, ty provedou rozdělení všech pixelů s vyšší intenzitou, než je práh  $T$  do jedné třídy, s tou nižší do druhé třídy. Problematikou je vhodná volba prahu tak, aby například nedošlo k potlačení obrazové informace. Samotné prahování se rozděluje do dvou základních skupin na lokální tresholding (metody, které umožňují kompenzaci globálních metod) a globální tresholding, který je nejvyužívanější. [23][24][25]

Základními přístupy pro prahování jsou Hard tresholding a Soft tresholding. Užívá se zde tzv. charakteristické funkce (Obrázek 9), definující pravidlo, které přiřazuje prvky z množiny  $X$  do podmnožiny  $A$ . Definují ji vztahy (6.1), (6.2).

$$\chi_A(x) = \begin{cases} 1, & \text{pokud } x \in A \\ 0, & \text{pokud } x \notin A \end{cases} \quad (6.1)$$

$$\mu_A(x) = \begin{cases} 1, & \text{pokud } x \in A \\ 0, & \text{pokud } x \notin A \\ (0; 1) - \text{vyjadřuje stupeň členství} \end{cases}, \quad (6.2)$$



Obrázek 9: Charakteristická funkce [23]

Obrazová segmentace využívá klasifikaci pixelů do regionů, které jsou dány příspěvky Kapurovy entropie, ta je dána vztahem (6.3):

$$\begin{aligned}
 H_1(t) &= - \sum_{i=0}^{t_1} \frac{p_i}{\omega_1} \ln \left( \frac{p_i}{\omega_1} \right), \omega_1 = \sum_{i=0}^{t_1} p_i \\
 H_2(t) &= - \sum_{i=t_1+1}^{t_2} \frac{p_i}{\omega_2} \ln \left( \frac{p_i}{\omega_2} \right), \omega_2 = \sum_{i=t_1+1}^{t_2} p_i \\
 H_n(t) &= - \sum_{i=t_{n-1}+1}^{L-1} \frac{p_i}{\omega_n} \ln \left( \frac{p_i}{\omega_n} \right), \omega_n = \sum_{i=t_{n-1}+1}^{L-1} p_i
 \end{aligned} \tag{6.3}$$

Hard thresholding představuje tzv. tvrdé či ostré prahování a řadí se zde OTSU metoda (Obrázek 10). Tato regionální segmentační metoda je jednou z nejvyužívanějších v oblasti globálního prahování. Využívá se více než jednoho prahu, vychází ze základu pro jeden threshold, kde histogram obsahuje pouze dva peaky a práh  $T$  je globálním minimem mezi nimi. Řídí se primárně dvěma kritérii pro klasifikaci:

1. Minimalizace vnitřního rozptylu třídy – intraclass variance. Definována vztahy (6.4), (6.5):

$$\sigma_w(t) = \omega_0(t)\sigma_0(t) + \omega_1(t)\sigma_1(t), \tag{6.4}$$

$$\omega_0(t) = \sum_{i=0}^{t-1} p(i), \omega_1(t) = \sum_{i=t}^{L-1} p(i), \tag{6.5}$$


kde  $\omega_0, \omega_1$  jsou třídni pravděpodobnosti,  
 $\mu_0, \mu_1$  jsou definovány jako třídni průměry.

2. Maximalizace mezí rozptylu – interclass variance. Vztahy (6.6), (6.7) pro maximalizaci rozptylu jsou následující:

$$\sigma_b(t) = \omega_0(t) \omega_1(t) [\mu_0(t) - \mu_1(t)]^2, \quad (6.6)$$

$$\mu_0(t) = \sum_{i=0}^{t-1} i \frac{p(i)}{\omega_0}, \mu_1(t) = \sum_{i=t}^{L-1} i \frac{p(i)}{\omega_0}, \quad (6.7)$$

kde  $\omega_0, \omega_1$  jsou třídni pravděpodobnosti,  
 $\mu_0, \mu_1$  jsou definovány jako třídni průměry.



Obrázek 10: Multilevel OTSU metoda

Do Soft tresholding prahování spadá Fuzzy aproximace, ta funguje na principu aproximace histogramu posloupností trojúhelníkovitých (Fuzzy) funkcí. Při zpracování může dojít k nekorektní jasové klasifikaci, tu zapříčiňuje šum, který disponuje odlišnou úrovní jasu. Metoda Fuzzy proto využívá lokální agregace, která slouží k modifikaci prostorové informace pro každý pixel a pracuje v prostoru členských funkcí. Lokální agregace se implementuje prostřednictvím kovoluce pro každý pixel, spadající do konkrétního regionu. Využívá se dvou základních agregátů (6.8), (6.9):

$$\text{Průměrový agregát (AvgAg): } \mu_l^s(I(r)) = \sum_{r_i \in \eta(r)} \omega_i \cdot \mu_l(I(r_i)), \quad (6.8)$$

$$\text{Mediánový agregát (MedAg): } \mu_l^s(I(r)) = \text{median}_{s \in \eta(r)} \{\mu(I(s))\} \quad (6.9)$$


Dalšími prahovacími technikami jsou Niblack prahování, Bayesian prahování či metoda isodata. [23][24][25]

### 6.1.2 Adaptivní prahování

Je metodou, využívající hodnoty prahu pro určení pouze určité části obrazu. Obraz je rozdělen do několika částí, na jejíž základě je určena hodnota prahu a pro jednotlivé části je následně provedeno prahování s konkrétním prahem. [19][24]

### 6.1.3 Shluková analýza – Clustering

Principem je shlukování pixelů s téměř totožnými vlastnostmi. Pixely jsou reprezentovány vektory, reprezentující výsledky měření z pixelů. Jako měření se definují barevné komponenty, rozptyl nebo střední hodnota. Samotná segmentace pak funguje jako výpočetní algoritmus pro shluky a následné vektorové přiřazení. Nejužívanější metodou je k-means, shlukující na základě výpočtu střední hodnoty a zařazení do dané třídy či fuzzy c-means. Princip je popsán na Obrázku 11. [19][23]



Obrázek 11: Shluková analýza [26]

### 6.1.4 Kohonenovy mapy


Jedná se o neuronové sítě, které využívají strategii soutěžního učení. Výsledné neurony tedy soutěží o to, aby mohli být aktivní, tudíž v určitém časovém okamžiku bude pouze jeden neuron aktivní. V Kohonenově mapě je každý výstupní neuron propojen vazbou se všemi neurony vstupními. Za vstupní neuron můžeme považovat jas pixelu, či jiné příznaky dostupné z obrazu. Vazba mezi výstupní a vstupní vrstvou neuronu má určitou váhu  $w$ . Soutěžení spočívá ve výpočtu vzdálenosti vektoru těchto vah. Vítězem se stává neuron s nejnižším výsledkem, přičemž vzdálenost obou vektorů (index  $c$ ), je možno vypočítat jako Eukleidovskou vzdálenost. Takto se postupně prochází tréninková množina, přičemž se vyhodnotí vítězný neuron a následně jsou upraveny jeho váhy, ale i váhy neuronů v jeho okolí. Úspěšnost závisí na vybraném počtu shluků a na počtu shluků při vstupu. [19]

#### 1.1.1 Markov Random Fields (MRF)

Statický model, jehož využití nalezneme v segmentaci obrazu. MRF metoda pracuje na základě modelování vazeb mezi sousedními a okolními pixely. Nevýhodou je náročná selekce řídicích parametrů, jenž ovlivňují vazby pixelů v obraze. Pokud by se parametry zvolily nevhodně, můžeme dostat nadměrně hladké hranice mezi segmenty a tím pádem ztrácíme důležité detaily. Mezi další nevýhody řadíme velkou výpočetní náročnost. I přes to jsou MRF modely velice rozšířené. Primární využití najdeme u modelování nehomogenity v obraze, či v modelování struktury segmentů. [19][21]

## 6.2 Detekce hran – edge-based

Detekce hran je jednou z nejvyžívanějších v segmentačních technikách, jedná se o body, které vykazují prudkou jasovou změnu. Ideálním modelem hrany je funkce step neboli skok. Jednotlivé typy hran uvádí Obrázek 12. [19][20]



Obrázek 12: Typy hran [19]

### 6.2.1 Hranové detektory

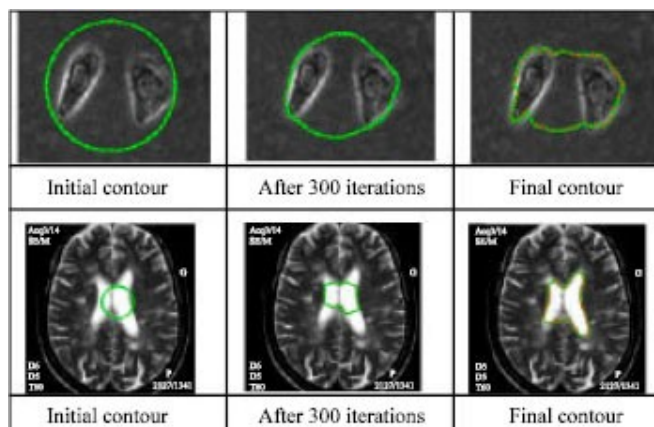
Principem je využití první či druhé derivace. Při užití první derivace se vypočte vertikální a horizontální gradient, výsledný gradient je z těchto dvou poté vypočten. Druhá možnost je užití druhé derivace, fungující na principu průchodu nulou. K detekci hran dojde tehdy, když je prostorová změna (v polaritě druhé derivace) příliš velká. [19][22]

### 6.2.2 Houghovy transformace

Klasická Houghova transformace identifikuje přímky v obraze, v současné době se užívá libovolných tvarů jako elips nebo kruhů. Velkou výhodou je odolnost vůči šumu. Obrazový prostor se mapuje do parametrového, to znamená, že se body mapují na křivku, křivky naopak na body. Následně probíhá hlasování – sčítání bodů, náležícím křivce, přímce či kružnici a hledá se maximum. [19]

### 6.2.3 Aktivní kontury

Metoda využívá tvarování kontur až k hranám objektu obrazu – Obrázek 13. Samotná aktivní kontura je složena z vnitřních a vnějších sil, které je potřeba správně definovat pro výslednou segmentaci. [19]



Obrázek 13: Aktivní kontury [27]

#### 6.2.4 Level-set metoda


Obdobná metoda jako metoda aktivních kontur, křivky se mění prostřednictvím level set funkce. Level set funkce je vícedimenzionální a řez nulovou hladinou (rovina  $xy$ ) definuje počáteční křivku. Každému bodu  $xy$  je přiřazena výška (nad nebo pod nulovou hladinou). Tento typ segmentace je výhodnější pro komplexní objekty složitých tvarů. [19][22]

### 6.3 Region-based metoda

Tato metoda, na rozdíl od hranových detektorů, detekuje v obraze celé oblasti. Výhodná je pro obrazy s velkým množstvím šumu, kde je detekce hran složitá. Podmínkou je homogenita obrazu v barvě, textuře apod.

#### 6.3.1 Region growing

Region growing (Obrázek 14) neboli metoda šíření oblasti seskupuje pixely s podobnou amplitudou k sobě a vytváří segmentovanou oblast. Využívá se s dalšími segmentačními technikami, v medicíně pro tumory či patologické léze. [19][23]



Obrázek 14: Region growing [28]

#### 6.3.2 Split and merge


Jak název napovídá, využívá se dělení a spojování oblastí, pokud jsou atributy nehomogenní podobraz je rozdělen na čtyři kvadranty. Pokud jsou čtverce naopak homogenní dojde ke spojení v jednu oblast. [19][23]

## 6.4 Hybridní metody

Pokud segmentační algoritmus nelze zařadit do žádné z předchozích skupin, nalezneme v hybridních metodách. Specifické pro tyto algoritmy je to, že používají některé prvky z předcházejících algoritmů. Patří sem:

### 6.4.1 Watershed transformace


Watershed transformaci na Obrázku 15 (rozvodí, povodí, vodní předěl) je možno zařadit do metod region-based. Jednotlivá povodí jsou z počátečních bodů zaplňována vodou. Tam, kde by mohlo dojít ke slítí dvou různých povodí jsou vytvořeny hráze. Výsledkem segmentace je obraz rozdělený na regiony, oddělené hrázemi. [19][25]



Obrázek 15: Watershed transformace [29]

### 6.4.2 Neuronové sítě

Segmentace založena na metodě „učení příklady“. Trénovat umělou neuronovou síť můžeme dvěma způsoby. – trénování bez učitele, kdy jsou vstupní data rozdělována do tříd, a učení s učitelem, kdy za vstup nepovažujeme pouze příznaky vektorů, ale také jejich funkce s přiřazením segmentu v obraze. GRBF metoda neuronové sítě, používána při segmentaci bílé a šedé mozkové kůry v obrazech magnetické rezonance, vznikla právě kombinací těchto dvou způsobů. Zobrazuje ji Obrázek 16. [19][25]



Obrázek 16: Neuronové sítě [30]



## 7 Použité vybavení

Před samotným zahájením obrazového zpracování bylo potřeba získat obrazová data. Byla použita skiografická kazeta pro nepřímou digitalizaci s rozměry 35 x 43 cm, standardně užívaná na radiodiagnostickém pracovišti Fakultní nemocnice Ostrava. Pro první část experimentu byl také použit stíněný box, který je vyroben z olova a tudíž, funguje jako dostatečné stínění vůči přírodní radiaci. Pro ověření byl k měření využit i dozimetr Polimaster PM-1621 (Obrázek 17), zapůjčený fyzikálním úsekem Kliniky nukleární medicíny FNO. Pro zpracování obrazu a statistické výpočty byl použit software Matlab R2016a.

### 7.1 Polimaster PM-1621

Jedná se o dozimetr, užívaný v oblasti osobní dozimetrie, který je schopen měřit i podprahové hodnoty, což bylo v práci potřeba. Tento typ měřidla se řadí do oblasti profesionálních dozimetrů pro zvláštní účely. Klasická osobní dozimetrie totiž nepracuje s tak nízkými dávkami, jako vykazuje přírodní radiace. Dozimetr má utěsněné pouzdro a umožňuje měřit ionizující záření, a to konkrétně gama záření (dávkový příkon, ten se určí z hodnoty střední absorbované dávky a radiačního váhového faktoru, její jednotkou je  $\mu\text{Sv/h}$ ), dále RTG záření (nízkoenergetické gama) a také celkovou dávku. Tabulka 1 uvádí jeho základní parametry. [31]

Tabulka 1: Základní parametry dozimetru Polimaster [31]

|                    | Polimaster PM-1621                                 |
|--------------------|--|
| Typ detektoru      | Geiger-Müllerův čítač                              |
| Dávkový příkon     | 0,01 - 200 000 / 0,01 - 2 000 000 $\mu\text{Sv/h}$ |
| Chyba měření       | $\pm 15 \%$  |
| Energetický rozsah | 0,01 – 20 MeV                                      |
| Třída ochrany      | IP67   |
| Připojení k PC     | Infračervený port                                  |




Obrázek 17: Dozimetr Polimaster PM-1621 [31]

## 8 Experiment akvizice obrazů a hodnoty dávek


Do středu skiografické kazety byl umístěn plát olověné gumy o rozměrech 5x5 cm, který se zafixoval kouskem lepící pásky. Páska byla užita z toho důvodu, že bylo potřeba při vyvolání kazety marker vždy sundat. Kazeta byla umístěna mimo oblast sledovaného i kontrolovaného pásma, jelikož by v nich mohlo působit sekundární ionizující záření a tento fakt bylo potřeba vyloučit. Již před zahájením experimentů se počítalo s faktem, že přírodní radiace nemůže vytvářet obrazy srovnatelné s obrazy způsobenými například sekundárním zářením či dokonce primárním. Po vyvolání obrazu byl snížen jas o  $-13 \text{ cd/m}^2$  a kontrast zvýšen o  $3 \text{ cd/m}^2$ . Změny těchto parametrů zvýšily pozorovací rozlišovací schopnost a obraz se stal pro pozorovatele lépe čitelný i při expozicích za krátký časový úsek.

V první části experimentu se posuzuje přírodní radiace a možný chemický vliv. Vstupním měřením se zjišťovalo, zdali se na obrazech, které by měly reprezentovat vliv přírodní radiace, nepodílí i jiné složky. Experiment byl proveden se stíněným olověným boxem, který plně absorbuje ionizující záření. Kazeta byla po dobu 1 týdne ponechána v uzavřeném boxu a následně vyvolána. Vzniklý obraz byl porovnán s výstupem, kde působila přírodní radiace rovněž 1 týden. Výsledné obrazy jsou uvedeny níže na Obrázku 18.




*Obrázek 18: Obraz po působení přírodní radiace a obraz v olověném boxu, oba po expozici za 1 týden*

Ze vzniklých obrazů lze již vizuálně soudit, že na obrazy pravděpodobně nepůsobí chemické vlivy, které by mohly ovlivňovat výsledek, je tedy pravděpodobné, že na obrazy působí právě přírodní radiace. Tento fakt je ale potřeba ověřit segmentací a následnou statistickou analýzou. Ověření, ještě poskytují segmentované obrazy (Obrázek 19 a Obrázek 20), které potvrzují fakt, že olověný plátek na snímcích vidět nelze, zatímco na kazetě po týdenní expozici mimo box, je přítomnost plátku zřetelná.



*Obrázek 19: Segmentace pěti regiony u snímku po expozici za týden*




*Obrázek 20: Segmentace pěti regiony u snímku po expozici za týden v olověném boxu*

Další část měření je cílená na vliv přírodní radiace a jeho matematické podložení. Byla provedena série měření po dobu 0 minut – referenční obraz, 24 hodin, dále 1, 2, 3 a 4 týdnů. Obrazy byly vyvolány a částečně upraveny jasově a kontrastně (všechny snímky stejně). U všech měření byl vedle kazety umístěn dozimetr, pro zjištění konkrétních hodnot dávky v určitém časovém úseku.

Tabulka 2: Hodnoty dávek v závislosti na rostoucím čase

| Čas                  | Dávka [ $\mu\text{Sv}$ ] |
|----------------------|--------------------------|
| 0 minut              | 0,00                     |
| 24 hodin             | 2,62                     |
| 1 týden (168 hodin)  | 18,28                    |
| 2 týdny (336 hodin)  | 35,95                    |
| 3 týdny (672 hodin)  | 68,54                    |
| 4 týdny (1344 hodin) | 135,23                   |

V Tabulce 2 je patrný nárůst dávky v závislosti na rostoucím čase. Dávka roste kontinuálně a dávkový příkon se pohyboval v rozmezí  $0,10 \mu\text{Sv/h} - 0,11 \mu\text{Sv/h}$ . Grafická vizualizace je na Obrázku 21.




Obrázek 21: Graf závislosti dávky na čase

## 8.1 Časově závislá data


Následující časově závislá data Obrázek 22, Obrázek 23 a Obrázek 24 znázorňují výsledky měření po již zmíněných časových úsecích. První Obrázek 22 (reference, vyvolaná za 0 minut) je bez jakýchkoli prvotních vizuálních znaků, jelikož při okamžitém vyvolání by přírodní ionizace neměla významně působit. U snímku, vyvolaného za 24 hodin je patrné již slabé působení přírodní radiace.






*Obrázek 22: Zleva: Referenční obraz za 0 minut, obraz za 24 hodin*

Obrázek 23 již znázorňuje snímky, vyvolané za 1 a 2 týdny po působení přírodní radiace. Na těchto snímcích je již patrný marker a jeho umístění lze zřetelně vidět.



*Obrázek 23: Zleva: Obraz za 1 týden, obraz za 2 týdny*


U Obrázku 24 je situace obdobná, jako u předchozího snímku. Marker je zřetelně a dobře viditelný u snímku za tři i za čtyři týdny.




*Obrázek 24: Zleva: Obraz za 3 týdny a za 4 týdny*

Následně jsou data zpracovávána pomocí vhodných segmentačních metod tak, aby se extrahovaly pouze potřebné oblasti a byl nalezen možný trend v hodnotách počtu pixelů či po provedené deskriptivní statistice hodnotách mediánů. Segmentace se provádí u všech obrazů, jelikož například u snímku za 24 hodin není marker zřetelně viditelný.

Pro práci se rovněž užívá obrazů z první série měření studentky Ostravské Univerzity, která pracovala s obdobným experimentem, nicméně nebyly měněny vstupní hodnoty jasu či kontrastu a experiment byl prováděn v časech 24 hodin, 48 hodin, 4 dny, 8 dní, 16 dní a 32 dní. Dva podobné experimenty s pozměněnými vstupními parametry budou sledovat možné rozdíly v predikčním modelu, v segmentaci a následných statistických výpočtech. Snímky jsou demonstrovány níže na Obrázku 25. Jak bylo zmíněno, v práci se bude pracovat s oběma měřeními a pro jednodušší rozlišení se snímky vyvolané pro tuto práci budou označovat jako snímky ze druhé série měření a snímky studentky Ostravské Univerzity jako snímky první série měření. Již z vizuální stránky je patrné, že bez úpravy jasu a kontrastu není na první pohled vidět oblast umístění olověného plátku.





*Obrázek 25: Snímky za 0 minut, 24 hodin, 48 hodin, 4, 8, 16 a 32 dní*

## 9 Komparativní analýza regionálně orientovaných segmentačních modelů

V této části práce se srovnávají dvě nejvhodnější metody pro segmentaci obrazových dat, reprezentujících vliv přírodního radiačního pozadí na degradaci kazet pro nepřímou digitalizaci. Pro měření byla využita skiagrafická kazeta o velikosti 35 x 43 cm. Do středu kazety byla umístěna olověná guma, reprezentující vhodný marker na měření s rozměrem 5x5cm. Srovnávají se metody Fuzzy a OTSU a hodnotí se, která metoda je vhodnější, neboť zpracovávané obrazy jsou z důvodu šumu pro detekci těžce hodnotitelné. Pro porovnání byly zvoleny stejné vstupní parametry a stejné obrazy. Segmentace byla rozdělena na třídy se 2, 5 a 10 regiony. Pozoruje se, která třída je pro zpracování nejoptimálnější a zároveň není extrémně časově náročná.

### 9.1 Komparativní analýza metod Fuzzy a OTSU

Pro matematické zhodnocení metod Fuzzy a OTSU a jejich optimální volbu byla provedena analýza na základě zjištěných parametrů pro střední kvadratickou chybu a korelační koeficient, reprezentující hodnotící parametry pro kvalitu obrazu. Vzhledem k vysoké intenzitě šumu u obrazů, které jsou podstatou této práce, je nebylo možno pro analýzu použít. Z tohoto důvodu byly užity klasické CT obrazy cévního řečiště a 3 základní typy šumů – Gaussovský šum, Salt & Pepper a Speckle. Sleduje se, jak dochází ke změnám parametrů u korelačního koeficientu a střední kvadratické chyby s rostoucím rozptylem (Gaussovský a Speckle) a hustotou šumu (Salt & Pepper). Předpokládá se, že by Fuzzy metoda měla být robustnější vůči přítomnosti šumu. Vše se ověřuje evaluačními parametry, a to střední kvadratickou chybou MSE (Mean Squared error), ta počítá chybu mezi vstupním snímkem, snímkem, který obsahuje zanedbatelné množství šumu a snímkem po aplikaci šumu. Výpočet uvádí vzorec (9.1):

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (x_{i,j} - y_{i,j})^2, \quad (9.1)$$

kde  $M$  je velikost obrazu na ose horizontální,  
 $N$  je velikost obrazu na ose vertikální,  
 $X_{i,j}$  definuje pixel segmentovaného snímku bez šumu (souřadnice  $i$  a  $j$ ),  
 $Y_{i,j}$  definuje pixel segmentovaného snímku, obsahující šum (souřadnice  $i$  a  $j$ ).

Čím nižší hodnota parametru MSE, za tím kvalitnější lze segmentaci považovat. [32]

Dalším matematickým ukazatelem kvality je korelace. Výpočet korelačního koeficientu  $r$  je dán poměrem kovariance u proměnných, které jsou vynásobeny prostřednictvím jejich směrodatných odchylek. Korelace je definována vztahem (9.2):

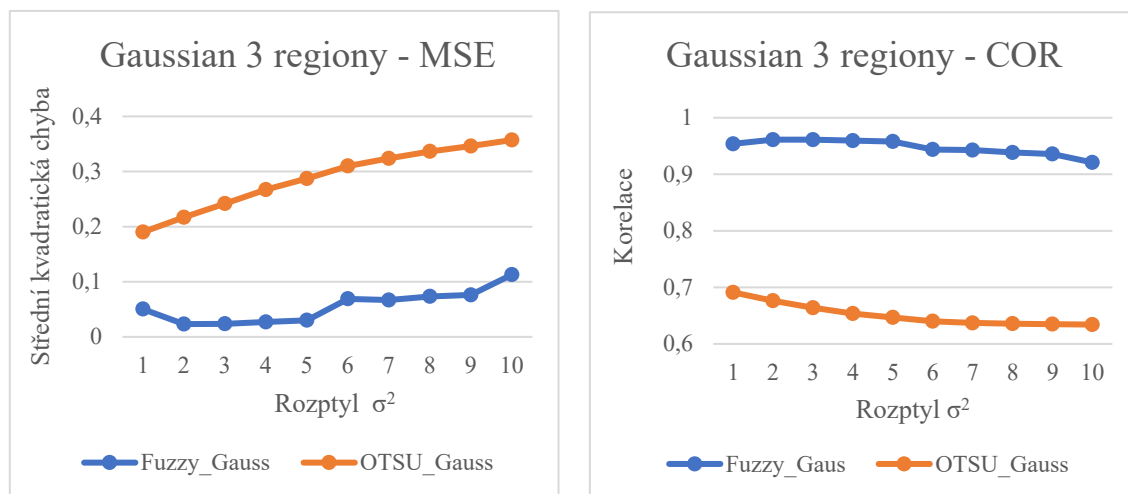
$$r = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}. \quad (9.2)$$

Výsledek se pohybuje v rozmezí od 0 do 1 a platí, že čím se hodnota  $k$  1 blíží více, tím se jedná o kvalitnější proces. Lze vyjádřit i v %. [33]

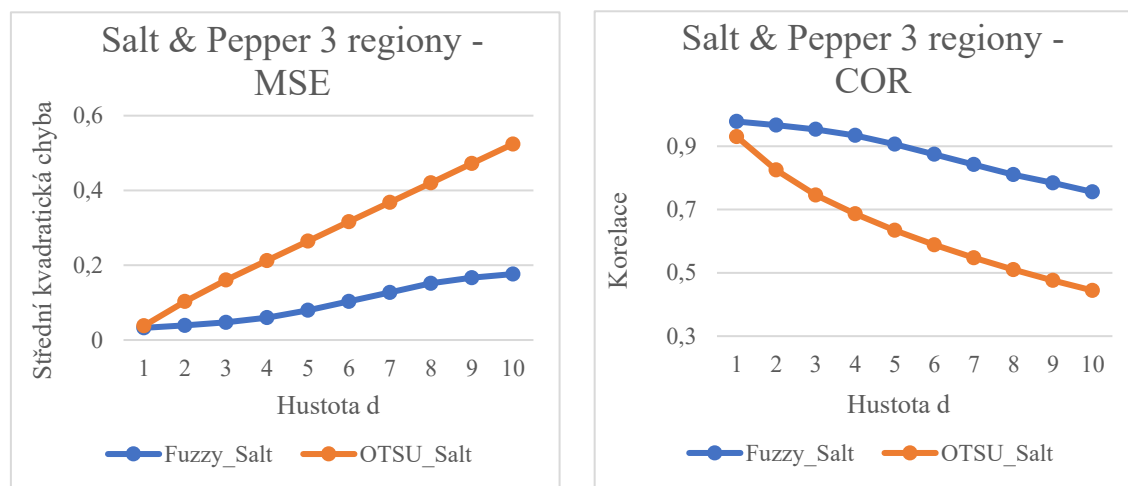


### 9.1.1 Šumová analýza pro 3 regiony

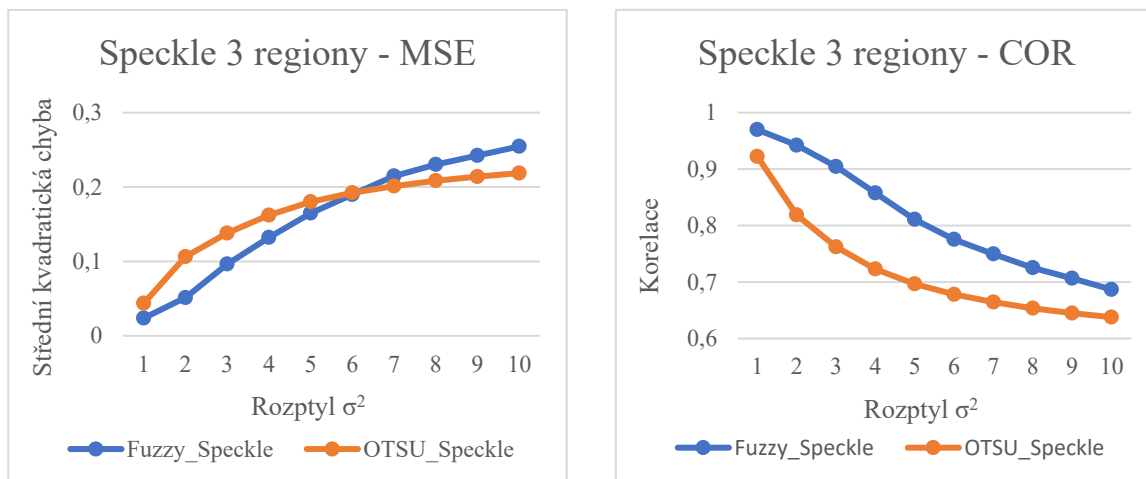
Jako první jsou parametry hodnoceny po segmentaci u OTSU a Fuzzy metody pro 3 regiony. Segmentace prostřednictvím 3 regionů rozděljuje obraz do 3 segmentačních tříd na jejichž základě sledujeme výslednou segmentaci. Pro deset hodnot rozptylu (od nejnižších pro nejvyšší, u obou segmentací totožné) se zjišťovaly parametry pro střední kvadratickou chybu a korelaci.



Obrázek 26: Grafy MSE a korelace pro Gaussovský šum pro 3 regiony



Obrázek 27: Grafy MSE a korelace pro šum Salt & Pepper pro 3 regiony



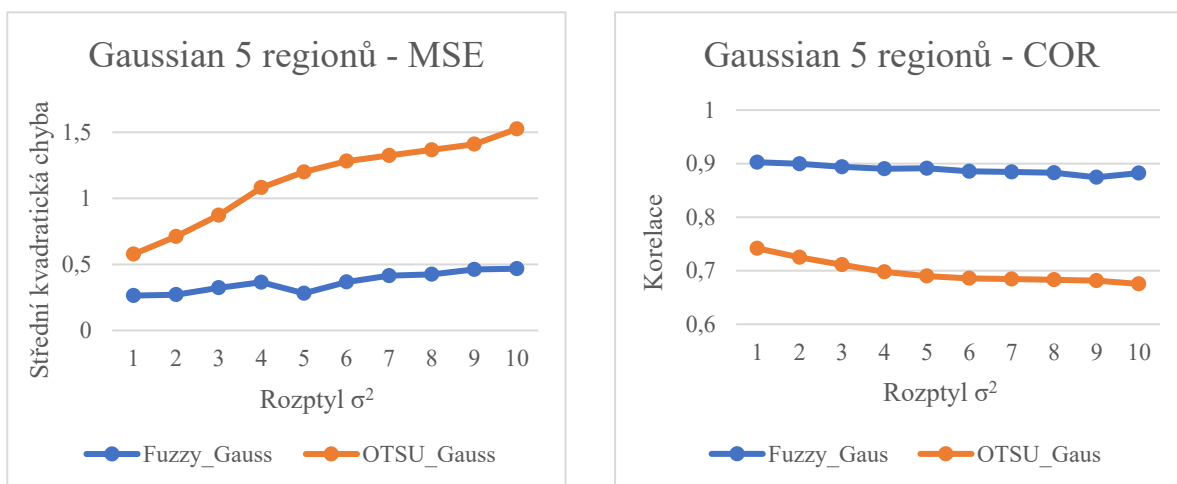
Obrázek 28: MSE a korelace pro šum Speckle pro 3 regiony

Z grafických prezentací Obrázek 26, Obrázek 27 a Obrázek 28 jsou u Gaussovského šumu a šumu Salt & Pepper dominující lepší výsledky u metody Fuzzy. U Gassovského šumu se hodnoty MSE po Fuzzy segmentaci pohybují v rozmezí 0,02 – 0,11 a pro OTSU segmentaci 0,19 – 0,36. U šumu Salt & Pepper pro Fuzzy segmentaci 0,03 – 0,18 a OTSU segmentaci 0,03 – 0,52. Hodnoty střední kvadratické chyby pro Fuzzy segmentaci jsou výrazně nižší, na základě tohoto parametr lze Fuzzy metodu považovat za kvalitnější. Nicméně u šumu Speckle jsou hodnoty MSE pro Fuzzy i OTSU téměř totožné, každá segmentace je výhodnější u jiných parametrů, a proto nejde objektivně říct, která z těchto metod je lepší.

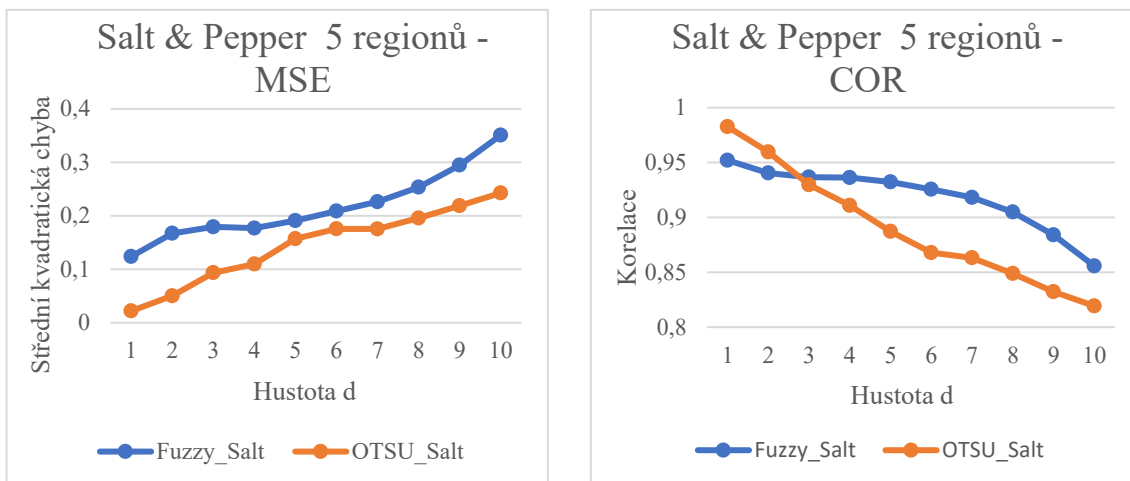
U korelace je situace obdobná a Fuzzy metoda je u všech třech typů šumů vyhodnocena jako lepší, jelikož se její hodnoty vždy více blíží k 1.

### 9.1.2 Šumová analýza pro 5 regionů

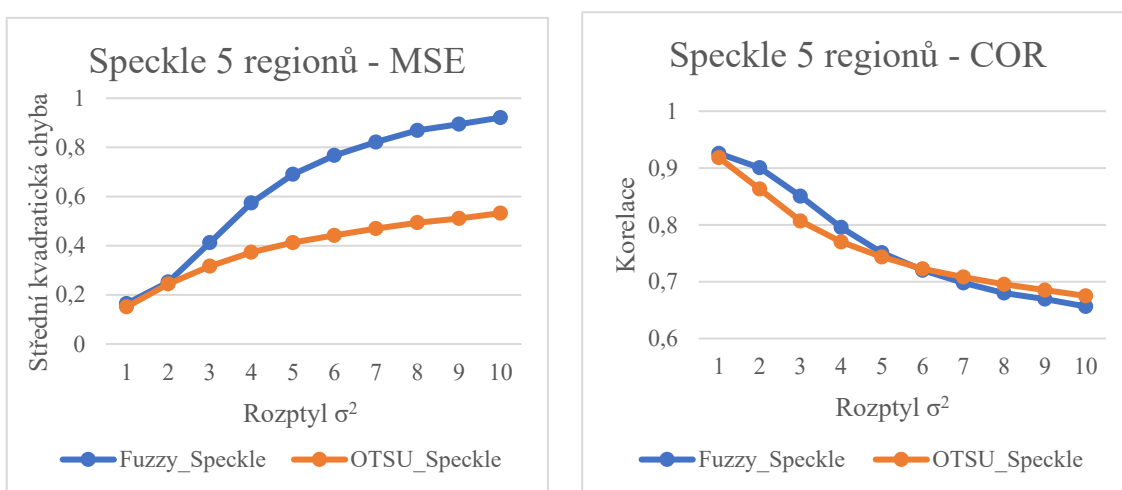
Analýza byla provedena také pro 5 segmentačních tříd a princip je obdobný jako u analýzy pro 3 regiony.



Obrázek 29: MSE a korelace pro Gaussovský šum pro 5 regionů



Obrázek 30: MSE a korelace pro šum Salt & Pepper pro 5 regionů




Obrázek 31: MSE a korelace pro šum Speckle pro 5 regionů

Zatímco u segmentace 3 regiony značně dominovala Fuzzy metoda u segmentace prostřednictvím 5 regionů je u MSE situace odlišná. Výsledky reprezentují Obrázek 29, Obrázek 30 a Obrázek 31. Gaussovský šum je opět vhodnější pro segmentaci pomocí Fuzzy metody, jeho hodnoty se pohybují v rozmezí 0,26 – 0,47, což je výrazně méně než u OTSU metody (0,58 – 1,53). U Zbývajících dvou šumů je výhodnější použití OTSU metody, jelikož nabývá vždy nižších hodnot než metoda Fuzzy, což je u MSE stěžejním parametrem.

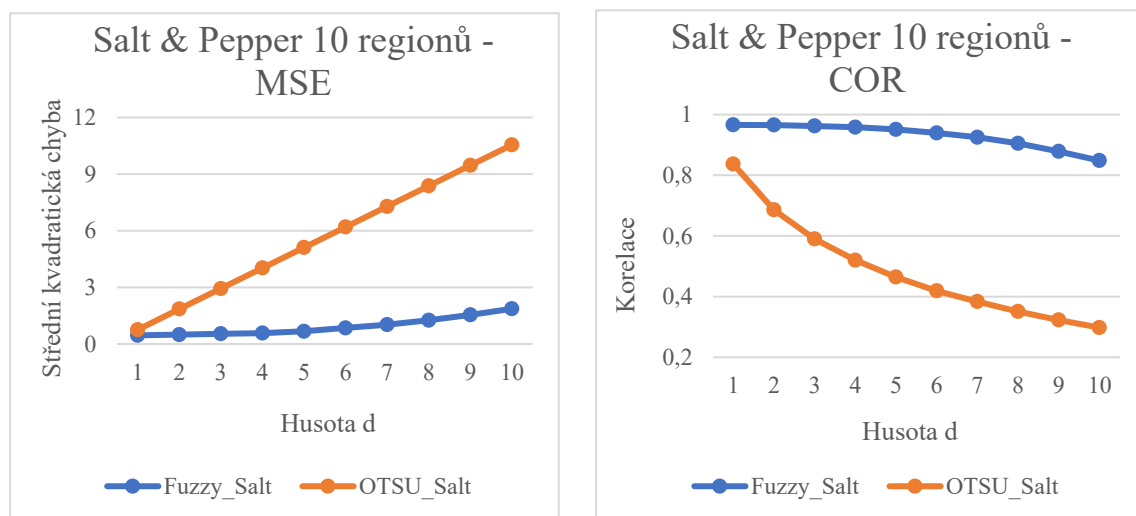
U hodnot korelace opět dominuje metoda Fuzzy, ačkoliv je u Salt & Pepper při nižších hodnotách rozptylu korelace opravdu vysoká, u Speckle nabývají metody téměř totožných hodnot.

### 9.1.3 Šumová analýza pro 10 regionů


Segmentace a výpočet korelace a MSE se provedl i pro 10 regionů. Výsledky demonstruje Obrázek 32, Obrázek 33 a Obrázek 34.



Obrázek 32: MSE a korelace pro Gaussovský šum pro 10 regionů



Obrázek 33: MSE a korelace pro šum Salt & Pepper pro 10 regionů



Obrázek 34: MSE a korelace pro šum Speckle pro 10 regionů

Analýza MSE a korelace za použití 10 regionů u metod OTSU a Fuzzy opět ukázala, že Fuzzy metoda se jeví jako výhodnější jak z pohledu střední kvadratické chyby, tak z pohledu korelace.

#### 9.1.4 Zhodnocení

Na základě analýzy metody OTSU a Fuzzy se Fuzzy metoda jeví jako lepší z pohledu segmentace a práce se šumem, potvrzuje také fakt, že si díky své robustnosti se šumem umí poradit lépe. Nicméně při segmentaci 5 regiony byly výsledky střední kvadratické chyby přikloněny k metodě OTSU, to však opět vyvrací hodnoty korelace, které jsou u Fuzzy metody vyšší, a tudíž hodnotí kvalitu segmentace jako lepší.


Díky výsledkům byl ověřen předpoklad, že Fuzzy metoda se šumem pracuje lépe a do práce by mohla být vhodnější. Důležité je také vizuální posouzení, které přinesou jednotlivé segmentace a také vhodně zvolený počet segmentačních tříd.

## 9.2 Výběr segmentační metody a počtu regionů pro segmentaci

Ke srovnání byl zvolen nejhůře a nejlépe čitelný obraz, tzn. obraz za 24 hodin a obraz vyvolaný za 4 týdny. U obou obrazů byly testovány segmentace se všemi regiony.

### 9.2.1 24 hodin – 2 regiony

Samotné segmentace jsou si velmi podobné (Obrázek 35), rozdíl je patrný až v binarizovaném obraze (Obrázek 36), kde se obrazová informace z OTSU metody téměř potlačila.



*Obrázek 35: Snímky po segmentaci 2 regiony*

U Fuzzy metody je sice informace rovněž hůře čitelná, avšak lze rozeznat oblast, kde byla uložena olověná guma. Pokud výsledný segmentovaný obraz Fuzzy metodou srovnáme s původním je patrné, že segmentace byla úspěšná a došlo k vystoupení přírodního pozadí, to na binarizovaném snímku reprezentuje černá barva. Binarizace OTSU metodou nepřináší očekávaný výstup a z vizuálního posouzení se nedá dobře rozpoznat, kde působí přírodní radiace a kde ne.




*Obrázek 36: Snímky po binarizaci a původní snímek*

### 9.2.2 24 hodin – 5 regionů


U rozdělení do pěti regionů je situace obdobná (Obrázek 37), avšak lépe by byl obraz segmentován při využití Fuzzy metody, což je patrné i u binarizovaného obrazu (Obrázek 38).





*Obrázek 37: Snímky po segmentaci 5 regiony*

Můžeme pozorovat i rozdílnou distribuci jednotlivých regionů. Zatím co u Fuzzy metody jsou nejvíce zastoupeny regiony 1 a 5, u OTSU nelze říct, který region je dominantní, to je také důvodem lepšího binarizovaného obrazu Fuzzy metodou.




*Obrázek 38: Snímky po binarizaci a původní snímek*

Je potřeba podotknout, že jsou obrazy vyvolány pouze po 24 hodinách působení přírodního radiačního pozadí, tudíž je zpracování poměrně náročné. Pět regionů se jeví jako neoptimálnější volba.

#### 1.1.2 24 hodin - 10 regionů

Při segmentaci 10 regiony se obraz zdá z vizuální stránky přesegmentovaný a obrazová informace je tlumená a nejasná (Obrázek 39).



Obrázek 39: Snímky po segmentaci 10 regiony




Obrázek 40: Snímky po binarizaci a původní snímek

Segmentace 10 regiony se již z vizuálního pohledu nejeví jako vhodná. V obrazech je příliš hodně šumu (Obrázek 40).


### 9.2.3 4 týdny – 2 regiony

Již při segmentaci pouze dvěma regiony (Obrázek 41) vystoupilo do popředí místo, kde byl uložen olověný plátek, a to u obou segmentačních metod. Fuzzy metoda poskytuje čistější oblast v místě uložení olověné gumy, OTSU metoda do tohoto místa zanáší i tmavé pixely.





*Obrázek 41: Snímky po segmentaci 2 regiony*




*Obrázek 42: Snímky po binarizaci a původní snímek*

U Fuzzy segmentace bylo binarizací získáno pouze radiační pozadí, působící na kazetu. OTSU segmentace vykazuje vyšší šumovost i v binarizovaném obraze na místě, kde byl uložen olověný plátek (Obrázek 42).

#### 9.2.4 4 týdny - 5 regionů

Z vizuálního hlediska je patrné (Obrázek 43), že si Fuzzy segmentace poradila se snímkem velmi dobře a potřebné informace jsou ze snímku zřetelně čitelné. I u OTSU metody je segmentovaný obraz čitelný, avšak ne tak dobře, jako u metody předešlé.



*Obrázek 43: Snímky po segmentaci 5 regiony*

Binarizace OTSU metodou (Obrázek 44) zcela potlačila jakoukoli jasovou informaci, naopak binarizace obrazu, zpracovaného Fuzzy metodou poskytla jasný výstup.




*Obrázek 44: Snímky po binarizaci a původní snímek*


#### 9.2.5 4 týdny – 10 regionů

Segmentace 10 regiony (Obrázek 45) opět na první pohled působí jako nadbytečná. Do oblasti uložení olověného plátku se zahrnují nadbytečné barevné pixely, což je především viditelné u metody OTSU. Díky tomu potřebná obrazová informace nevystoupila, ale je naopak potlačena a narušena šumem.





Obrázek 45: Snímky po segmentaci 10 regiony



Obrázek 46: Snímky po binarizaci a původní snímek

Výsledná binarizace (Obrázek 46) je u Fuzzy metody čitelná, zahrnuje však nadbytečné pixely v oblasti uložení olovené gumy. U binarizace OTSU metody nedošlo k zisku radiačního pozadí ze snímku a segmentaci nelze použít.

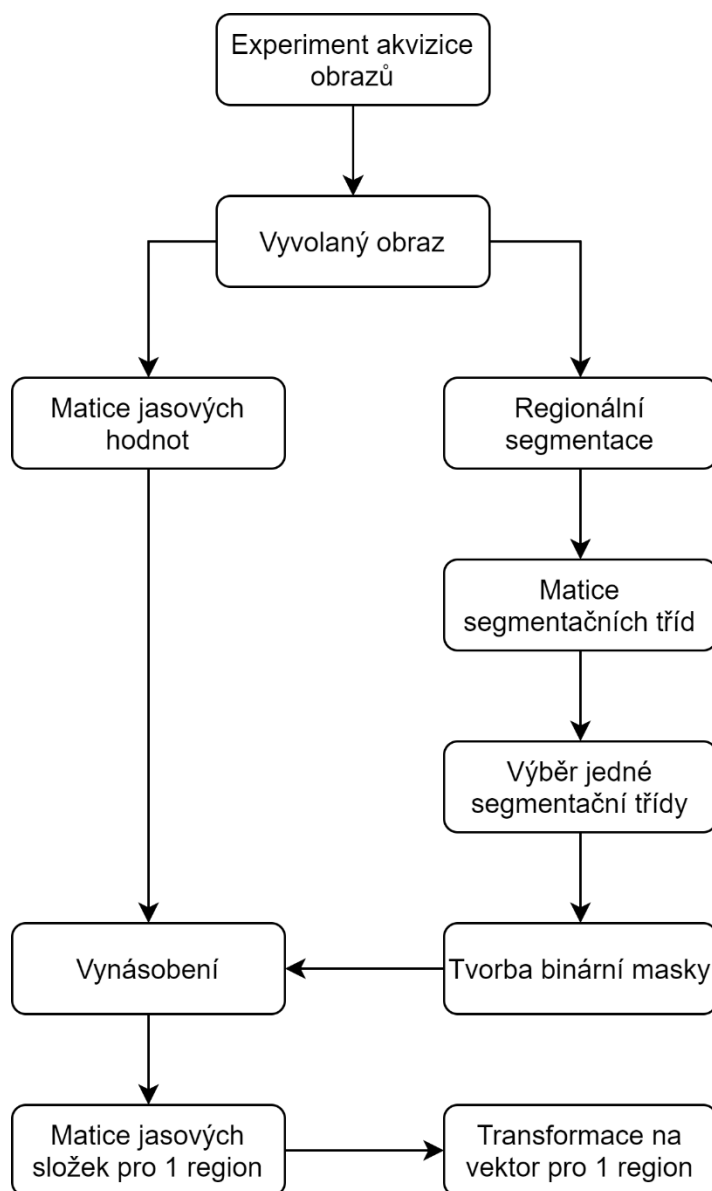
### 9.3 Zhodnocení a zdůvodnění výběru

V této části práce byly zhodnoceny vhodné metody pro zpracování, a to metody prahování Fuzzy a OTSU. Metoda OTSU spadá do tzv. Hard thresholding a s obrazy, které bylo potřeba zpracovat si v některých případech neporadila dobře. Výstupní informace nebyly čitelné a z binarizovaných obrazů nešel vyčíst požadovaný parametr – přírodní pozadí. Metoda Fuzzy, spadající do Soft thresholding metod, se pro potřeby práce jevila jako výhodnější z hlediska zpracování obrazové informace a výstupů, které poskytovala. Zároveň potvrdila předpoklad z provedené matematické analýzy. Obrazy byly čitelné a prahovací metoda Fuzzy si lépe poradila se šumem než metoda OTSU.

Jako optimální počet segmentačních tříd byla zvolena hodnota 5. I přes to, že se u snímků vyvolaných za 32 dní jevílo použití 2 tříd jako dostačující, u snímků za 24 hodin tomu tak nebylo. 10 segmentačních tříd bylo v obou případech zbytečně vysoké, ať už z hlediska potlačení výstupní obrazové informace, tak (u Fuzzy metody) z hlediska časové náročnosti. Pět segmentačních tříd je optimálním prahem pro zpracování snímků, na něž působí přírodní pozadí, jelikož jeho intenzita záznamu je poměrně slabá.

## 10 Návrh matematického modelu pro objektivizované hodnocení vlivu přírodní radiace na kvalitu paměťových fólií


Matematický model, zpracovávající vliv přírodní radiace je demonstrován pomocí Fuzzy segmentace. Ta se jeví z hlediska segmentačních technik, pracujících na principu prahování jako nejvhodnější. Na Obrázku 47 je znázorněn vývojový diagram pro proces segmentace a následný převod do potřebné podoby pro statistickou analýzu.



Obrázek 47: Vývojový diagram procesu získání vektoru jasových složek

V této části byly nastaveny shodné vstupní parametry pro zpracování. Jako nejvhodnější počet segmentačních tříd byla zvolena hodnota 5, což bylo zhodnoceno v předešlé kapitole „Komparativní analýza regionálně orientovaných segmentačních modelů“. U Fuzzy metody bylo nastaveno okno mediánového agregátu o velikosti 3x3, tento vstupní parametr byl užít na všechny snímky. Byly


testovány také rozdílné velikosti okna pro Fuzzy segmentaci. Při zvětšení okna mediánového agregátu došlo k lepší segmentaci, avšak došlo k velkému potlačení segmentačních tříd 2, 3 a 4. Do popředí vystoupily pouze regiony 1 a 5. Při dalším zpracování snímků došlo ke značnému přesegmentování, tudíž se jako optimální volba zvolila již zmíněná velikost mediánového okna 3x3.







Obrázek 48: Zleva: Referenční obraz zpracovaný metodou Fuzzy a jeho histogram

Na referenčním obraze (Obrázek 48) převládá region 5, tento region reprezentuje oblasti, kde nepůsobí radiační pozadí. I přes fakt, že Fuzzy metoda pracuje lépe se šumem, na referenčním obraze jsou patrné známky působení přírodní radiace, což ukazuje i uvedený histogram obrazu. U OTSU obrazu dominuje pouze 5. region, tudíž došlo k vyhlazení zbytkového šumu.

U všech obrazů je následně provedena Fuzzy segmentace, obrazy jsou seřazeny vzestupně dle času.













*Obrázek 49: Segmentace pěti regiony pro obrazy za 24 hodin, 1, 2, 3 a 4 týdny a jejich příslušné histogramy*







Byly provedeny segmentace pro všechny obrazy od 24 hodin po 4 týdny (Obrázek 49). Z vizuálního hlediska je patrné, že přírodní pozadí zvyšuje svou intenzitu na snímcích z kazet pro nepřímou digitalizaci s rostoucím časem. Je rovněž patrné, že nejvyšší zastoupení mají regiony 1 a 5. Region 5 také s rostoucím časem již z prvního pohledu klesá, u ostatních regionů je patrná rozdílná distribuce vzhledem k času. Pozorovaná oblast uložení olověné gumy je s rostoucím časem jasněji viditelná. U všech obrazů nelze pouhým okem, při tomto rozlišení, vidět zastoupení regionů 2, 3 a 4, proto jsou zde zařazeny také histogramy pro jednotlivé snímky.


Následně byly provedeny segmentace Fuzzy metodou s užitím pěti regionů i pro obrazy z první série měření, které prováděla studentka Ostravské Univerzity. Segmentace a následná práce s těmito snímky se zde prováděla z toho důvodu, že pro druhou sérii měření, která byla provedena pouze pro tuto práci byly změněny vstupní parametry, jak je uvedeno v kapitole „Experiment akvizice obrazů a hodnoty dávek“.

Stejná segmentace byla provedena také pro snímky z první série měření od studentky Ostravské Univerzity. Výstupy a jejich histogramy jsou reprezentovány níže na Obrázku 50. Snímky nebyly žádným způsobem upravovány, byly použity snímky totožné s těmi, se kterými sama autorka pracovala. Již na první pohled je patrné, jak se změna kontrastu a jasu (která byla provedena pro druhou sérii měření) projevuje na segmentovaných snímcích a jejich histogramech. Jediný snímek, který má segmentaci velmi podobnou je snímek vyvolaný jako referenční, tzn. za 0 minut.









*Obrázek 50: Shora: Snímek za 0 minut, 24 hodin, 48 hodin, 4, 8, 16 a 32 dnů a jejich příslušné histogramy*

Pro realizaci statistických výpočtů byla potřeba vyseparovat konkrétní hodnoty jasu pro každý region zvlášť. Bylo to provedeno prostřednictvím softwaru Matlab R2016a. Pro provedení segmentace vznikla matice segmentů (pro každý region odlišných rozměrů) od 1 do 5, jelikož pracujeme s pěti segmentačními třídami. Pro každý obraz vznikla matice rozdílných distribucí. Reprezentuje ji Obrázek 51. Abychom mohli každý region hodnotit zvlášť, bylo potřeba separovat ze segmentační matice pouze hodnoty, vztahující se ke konkrétní třídě, vytvořit binární masku a tu vynásobit se vstupní maticí hodnot nezpracovaného obrazu.

Pro tvorbu binární masky byl použit příkaz v Matlabu, fungující na principu vrácení mapování datové mřížky, identické se vstupní mřížkou tak, že každý prvek  $Z$  s hodnotou obsaženou ve vektoru vstupní matice je nahrazen odpovídajícím prvkem nového vektoru.

1024x837 double

|    | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 |  |
|----|---|---|---|---|---|---|---|---|--|
| 1  | 1 | 1 | 1 | 1 | 5 | 1 | 1 | 1 |  |
| 2  | 1 | 1 | 1 | 5 | 5 | 5 | 5 | 5 |  |
| 3  | 4 | 4 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 4  | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 5  | 1 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 6  | 5 | 5 | 5 | 5 | 5 | 5 | 4 | 4 |  |
| 7  | 1 | 5 | 5 | 5 | 5 | 5 | 5 | 4 |  |
| 8  | 1 | 5 | 5 | 5 | 5 | 5 | 5 | 4 |  |
| 9  | 5 | 5 | 5 | 5 | 5 | 5 | 4 | 4 |  |
| 10 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 11 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 12 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 13 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 14 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 15 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 16 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |
| 17 | 5 | 5 | 5 | 5 | 5 | 5 | 5 | 5 |  |

Obrázek 51: Matice segmentovaného obrazu

Na Obrázku 52 je uvedena ukázka kódu. Funkce pracuje tak, že vstupní maticí hodnot (od 1 do 5) přiřadí, na základě třídy, se kterou chceme pracovat, hodnotu 0 nebo 1. Hodnota 0, je přiřazena všem ostatním třídám, se kterými v dané chvíli nechceme pracovat. Hodnota 1 je přiřazena regionu, se kterým pracovat naopak chceme. V uvedeném kódu chceme vyseparovat pouze region 3, tudíž je regionu 3 přiřazena hodnota 1 a všem ostatním regionům hodnota 0. Získáme binární masku, která má na pozicích regionu 3 hodnotu 1 a na všech ostatních hodnotu 0.

```
%% Tvorba binární masky ze segmentační třídy
bin_mask_reg3 = changem(fuzzy,[0 0 1 0 0],[1 2 3 4 5])
```

Obrázek 52: Kód pro tvorbu binární masky

Dalším krokem je převod na stejný datový typ *double* a vynásobení binární masky se vstupní maticí jasových hodnot. Výsledkem je matice, obsahující pouze hodnoty jasu pro 3. region, která obsahuje jak hodnoty jasu pro konkrétní pozici, tak nulové hodnoty, pro ostatní regiony. Matice je následně převedena do sloupcového vektoru, jelikož pro statistické výpočty je nutno pracovat s vektory hodnot a zároveň jsou odstraněny nulové hodnoty. Nově vzniklý vektor jasových hodnot koresponduje s hodnotami konkrétního počtu pixelů, které reprezentují histogramy. Jejich přesné hodnoty jsou uvedeny v následující kapitole.

## 11 Statistická analýza časově-závislých charakteristik vlivu radiačního pozadí na kazety pro nepřímou digitalizaci

Základní myšlenkou pro provedení statistických analýz bylo rozložení jednotlivých dat a hledání možného trendu, z něž by bylo možno zjistit, jakým způsobem bude kazeta s rostoucím časem a dopadající dávkou ovlivněna. Dále je potřeba potvrdit předpoklad, že se opravdu jedná o přírodní radiaci, která působí na kazetu, a ne o jiné vlivy.

Prvním krokem statistické analýzy zjištěných výsledků bylo vynesení počtu pixelů pro jednotlivé regiony v závislosti na jejich distribuci v čase do grafické podoby. Z histogramů, uvedených v předchozí kapitole byly odečteny přesné hodnoty počtu pixelů pro každý region a čas zvlášť. Vše se provádělo pro distribuci prostřednictvím rozdělení do pěti segmentačních tříd.

Abychom byli schopni se dobře orientovat ve zpracovávaných datech, které vykazují poměrně vysokou komplexitou je zde pro všechny časy a všechny regiony dohromady, a poté pro každý region zvlášť provedena deskriptivní statistika. Ta zahrnuje dvě dělní dle míry polohy a míry variability.

Každá část rovněž obsahuje dvouvýběrové charakteristiky, kombinující všechny možnosti, které mohou nastat a také vícevýběrové charakteristiky. Je zde doplnění o příslušné QQ-grafy a boxploty.

### 11.1 Použité proměnné a metody statistiky

**Horní kvartil** odděluje jednu čtvrtinu nejvyšších hodnot od zbytku. [34]

**Dolní kvartil** je opakem kvartilu horního pro nejnižší hodnoty. [34]

**Aritmetický průměr** je průměrem všech hodnot ve zkoumaném souboru. Jedná se o součet všech proměnných a následné vydělení jejich počtem. [33]

**Medián** je percentil padesáti procent a zároveň prostřední hodnota v datech u seřazeného souboru. U sudých čísel je průměrem z prostředních dvou. [35]

**Směrodatná odchylka** je odmocninou z rozptylu náhodné veličiny a definována vztahem (11.1):


$$\sigma = \sigma^2 = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}, \quad (11.1)$$

kde  $\sigma^2$  je rozptyl,  
 $n$  je počet prvků statistického souboru,  
 $x_i$  je prvek statistického souboru s indexem  $i$ ,  
 $\bar{x}$  je aritmetický průměr.

Zároveň je mírou variability a vypovídá o tom, jak moc se jednotlivé případy zkoumaných hodnot v souboru od sebe liší. [36]


**Variační koeficient** posuzuje relativní velikost rozptýlenosti hodnot vztažených k průměru a může se uvádět v procentech. [35]

**QQ graf** neboli kvantil-kvantil graf (Obrázek 53), podává informaci o normálním rozložení dat. Jedna osa obsahuje kvantily z hypotetického normálního rozdělení a druhá kvantily ze zkoumaného souboru. V ideálním případě náleží všechny body přímce. [37]




Obrázek 53: QQ grafy [vlastní zdroj]

**Boxplot** či krabicový graf (Obrázek 54) vizualizuje data pomocí jejich kvartilů a ve středu krabice je oddělen mediánem. Můžou zde být obsaženy tzv. vouseky, což jsou linie, které jdou ze střední části grafu kolmo nahoru a vyjadřují variabilitu dat pod 1. a nad 3. kvartilem. Součástí boxplotu můžou být i odlehlé hodnoty. [37]



Obrázek 54: Boxplot [vlastní zdroj]

**Histogram** je sloupčovým grafem, zobrazujících statistické informace z dat. Na vertikální ose jsou vyneseny třídy, na horizontální četnosti (relativní četnosti). V ideálním případě histogram prolíná Gaussovská křivka. Demonstruje ho Obrázek 55. [35]



Obrázek 55: Histogram s proloženou ideální Gaussovskou křivkou [38]

**Kolmogorův-Smirnov test** je neparametrický test, ověřující, zdali data pocházejí z normálního rozdělení. Oboustranný test pro spojitou distribuční funkci, testující nulovou hypotézu, že data jsou distribucí z normálního rozložení, oproti alternativě, že nikoli. Testovací statistika pracuje na principu výpočtu maxima absolutního rozdílu mezi empirickou SDF (spojitá distribuční funkce), vypočtenou ze vzorku dat a hypotetickou SDF. Výpočet se provádí dle vzorce (11.2):

$$D = \max(|\hat{F}(x) - G(x)|), \quad (11.2)$$

kde  $\hat{F}(x)$  je empirická SDF,  
 $G(x)$  je hypotetická SDF. [39]

**Levenův test** se používá pro vícenásobné testování rozptylu. Statistiky testu jsou:

$$W = \frac{(N-k) \sum_{i=1}^k N_i (\bar{Z}_i - \bar{Z})^2}{(k-1) \sum_{i=1}^k \sum_{j=1}^{N_i} (Z_{ij} - \bar{Z}_i)^2}, \quad (11.3)$$

kde  $N_i$  je velikost vzorku i-té skupiny,  
 $k$  je počet skupin,  
 $Z_{ij} = |Y_{ij} - \bar{Y}_i|$ , kde  $\bar{Y}_i$  je průměr i-té podskupiny.

Statistika testu má distribuci F s  $k-1$  stupni volnosti čitatele a  $N-k$  stupni volnosti jmenovatele. [40]

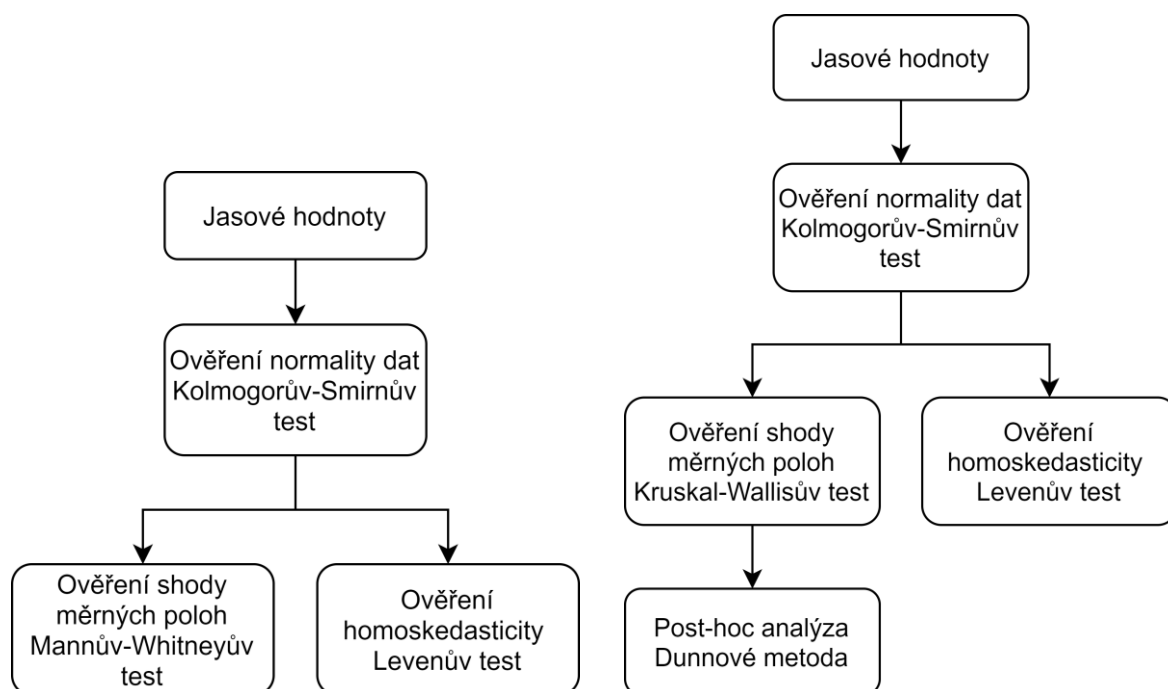
**Mannův-Whitneyův U-test** testuje, u neparametrických dat, shodu mediánů. „U“ značí kolikrát  $y$  předchází  $x$  v uspořádaném množství prvků ve dvou nezávislých vzorcích  $X$  a  $Y$ . Jelikož Matlab nenabízí možnost užití Mannova-Whitneyova testu je použit ekvivalentní Wilcoxonův test. Souvislost Mannova-Whitneyova a Wilcoxonova testu souvisí se statistikou součtové hodnoty: Pokud  $X$  je vzorek velikosti  $n_X$  pak se definuje rovnicí (11.3)[41]:

$$U = W - \frac{n_x(n_x + 1)}{2}. \quad (11.3)$$

**Kruskal-Wallisův test** je neparametrická forma klasického testu ANOVA a rozšíření Wilcoxonova testu na více než dvě skupiny. Srovnává střední hodnoty u skupiny dat a určuje, zda vzorky pocházejí ze stejné populace, či z různých populací se stejným rozložením. Vyhledává pozice seřazením dat od nejmenších k největším napříč všemi skupinami a pomocí číselného indexu tohoto uspořádání. Pořadí pro svázaná pozorování se rovná průměrnému pořadí všech pozorování, která jsou s ním svázaná. F-statistika, která se používá u ANOVA testu je nahrazená chí-kvadrát statistikou a p-hodnota měří právě jí. [42]

**Metoda Dunnové** je metodou post-hoc analýzy Kruskal-Wallisova testu v případě, že je zamítnuta nulová hypotéza. Test vícenásobného srovnání porovnává rozdíl v součtu řad mezi dvěma sloupci s očekávaným průměrným rozdílem (na základě počtu skupin a jejich velikostí). [43]

Vývojové diagramy pro statistickou analýzu dvouvýběrových a vícevýběrových testů jsou uvedeny na Obrázku 56.



Obrázek 56: Zleva: Vývojový diagram pro dvouvýběrové testy a pro vícevýběrové testy


## 11.2 Závislost distribuce pixelů na čase

Každý region se vyznačuje rozdílnou distribucí jasových intenzit, jejichž součet znázorňuje Tabulka 3. Data jsou odečtena z histogramů, které jsou uvedeny v kapitole „Návrh matematického modelu pro objektivizované hodnocení vlivu přírodní radiace na kvalitu paměťových fólií“. Toto je aplikováno pro první i druhou sérii měření.

Tabulka 3: Distribuce pixelů v závislosti na čase pro druhou sérii měření

| Čas/Region | 1                  | 2                  | 3                  | 4                  | 5                  |
|------------|--------------------|--------------------|--------------------|--------------------|--------------------|
| 0 minut    | 974                | 5                  | $3,147 \cdot 10^4$ | 0                  | $8,198 \cdot 10^5$ |
| 24 hodin   | $4,302 \cdot 10^5$ | 5119               | $1,646 \cdot 10^4$ | $2,819 \cdot 10^4$ | $3,709 \cdot 10^5$ |
| 1 týden    | $5,784 \cdot 10^5$ | 9619               | 6718               | $1,154 \cdot 10^4$ | $2,509 \cdot 10^5$ |
| 2 týdny    | $5,477 \cdot 10^5$ | $2,807 \cdot 10^4$ | $2,914 \cdot 10^4$ | $4,020 \cdot 10^4$ | $2,160 \cdot 10^5$ |
| 3 týdny    | $5,791 \cdot 10^5$ | $2,754 \cdot 10^4$ | $2,492 \cdot 10^4$ | $6,579 \cdot 10^4$ | $1,597 \cdot 10^5$ |
| 4 týdny    | $5,192 \cdot 10^5$ | $3,698 \cdot 10^4$ | $2,925 \cdot 10^4$ | $1,801 \cdot 10^5$ | $9,363 \cdot 10^4$ |





Obrázek 57: Závislost počtu pixelů na čase pro jednotlivé segmentační třídy ve druhé sérii měření


Vynesím do grafické podoby (Obrázek 57) je možné pozorovat klesající trend v 5 segmentační třídě, což nám potvrzují i přesné hodnoty v Tabulce 3. U ostatních segmentačních tříd žádný opakující se trend nalezen nebyl. Tabulka četností pixelů a jejich grafická závislost byla vytvořena také pro 1. sérii měření. Lze vidět trend ve 2 a 5 regionu. Ostatní regiony žádný trend nevykazují.

Tabulka 4: Distribuce pixelů v závislosti na čase pro první sérii měření

| Čas/Region | 1                  | 2                  | 3                  | 4                  | 5                  |
|------------|--------------------|--------------------|--------------------|--------------------|--------------------|
| 0 minut    | 860                | 5                  | $3,063 \cdot 10^4$ | 0                  | $8,235 \cdot 10^5$ |
| 24 hodin   | $3,904 \cdot 10^5$ | $0,745 \cdot 10^4$ | $1,404 \cdot 10^4$ | $2,076 \cdot 10^4$ | $4,234 \cdot 10^5$ |
| 48 hodin   | $4,354 \cdot 10^5$ | $1,009 \cdot 10^4$ | $1,370 \cdot 10^4$ | $1,327 \cdot 10^4$ | $3,856 \cdot 10^5$ |
| 4 dny      | $4,841 \cdot 10^5$ | $2,333 \cdot 10^4$ | $2,635 \cdot 10^4$ | $2,804 \cdot 10^4$ | $2,920 \cdot 10^5$ |
| 8 dní      | $3,688 \cdot 10^5$ | $5,340 \cdot 10^4$ | $7,047 \cdot 10^4$ | $7,302 \cdot 10^4$ | $2,024 \cdot 10^5$ |
| 16 dní     | $3,115 \cdot 10^5$ | $8,086 \cdot 10^4$ | $1,357 \cdot 10^5$ | $1,490 \cdot 10^5$ | $1,546 \cdot 10^5$ |
| 32 dní     | $3,162 \cdot 10^5$ | $9,106 \cdot 10^4$ | $1,351 \cdot 10^5$ | $1,430 \cdot 10^5$ | $1,525 \cdot 10^5$ |

Tabulka 4 udává hodnoty pixelů pro jednotlivé histogramy u Fuzzy metody, většina hodnot se pohybuje v řádech  $10^4 - 10^5$ . Jsou zde přítomny i velmi nízké hodnoty, ty jsou však pouze u referenčního obrazu, vyvolaného za 0 minut a tyto hodnoty lze očekávat, jelikož by obraz měl být téměř 100% čistý, tudíž především zastoupený regionem 5.

Z tabulkových hodnot byl vynesena graf na Obrázku 58, na němž je znázorněna časová závislost na počtu pixelů daného regionu v segmentovaném obraze.



Obrázek 58: Závislost počtu pixelů na čase pro jednotlivé segmentační třídy v první sérii měření

Z hlediska časově-závislé charakteristiky je číselně i vizuálně patrné, že 5 region má s rostoucím časem klesající trend. Také 2 region vykazuje určitý pozvolně rostoucí trend v závislosti na rostoucím čase. Ostatní regiony (1, 3 a 4) nevykazují žádný trend. Je možné, že dochází ke vzájemnému ovlivňování segmentačních tříd 1, 2, 3 a 4, reprezentujících přírodní radianci, a jejich distribuce není v případě zpracování obrazu v tak krátkém časovém úseku možné predikovat.

### 11.3 Deskriptivní statistické údaje pro druhou sérii měření

Jak bylo zmíněno v úvodu této kapitoly, vzhledem k vysoké komplexitě dat je provedena popisná statistika pro všechny proměnné. Deskriptivní statistika je provedena pro všechny časy v rámci jednoho regionu, dále pro všechny regiony v rámci jednoho časového úseku, a také pro jednotlivé regiony zvlášť. Zároveň jsou pro každý region zvlášť provedeny dvouvýběrové a vícevýběrové testy.

Vzhledem k velkému objemu dat bylo potřeba využívat software Matlab R2016a, který je schopen pracovat s těmito daty.

*Tabulka 5: Deskriptivní statistické údaje pro všechny časy v rámci jednoho regionu*

| Region                  | 1       | 2      | 3      | 4      | 5       |
|-------------------------|---------|--------|--------|--------|---------|
| Počet jasových složek   | 2653540 | 100206 | 137762 | 335218 | 1910965 |
| <b>Míry polohy</b>      |         |        |        |        |         |
| Maximum                 | 254     | 248    | 254    | 175    | 254     |
| Horní kvartil           | 96      | 93     | 116    | 101    | 254     |
| Minimum                 | 1       | 9      | 23     | 20     | 1       |
| Dolní kvartil           | 71      | 79     | 85     | 84     | 100     |
| Průměr                  | 83,7    | 86,3   | 126,1  | 92,3   | 166,7   |
| Medián                  | 83      | 85     | 92     | 94     | 119     |
| <b>Míry variability</b> |         |        |        |        |         |
| Směrodatná odchylka     | 18,5    | 13,2   | 70,2   | 13,8   | 76,8    |
| Variační koeficient (%) | 22,1    | 15,3   | 55,7   | 14,9   | 46,1    |

Z Tabulky 5 můžeme sledovat lineárně rostoucí změny hodnoty mediánu, zatímco u regionu 1 je medián nejnižší – 83, u regionu 5 je naopak nejvyšší – 119. Stejnou dynamiku vykazuje také dolní kvartil. Nejvyšší výkyvy jsou patrné u regionu 3, ten má nejvyšší směrodatnou odchylku i variační koeficient, překračující 50 % a tudíž lze tvrdit, že jasové hodnoty, které jsou obsaženy v regionu 3 jsou značně rozptýlené.

Tabulka 6: Deskriptivní statistické údaje pro všechny regiony v rámci jednoho časového úseku

| Čas                     | 0 minut | 24 hodin | 1 týden | 2 týdny | 3 týdny | 4 týdny |
|-------------------------|---------|----------|---------|---------|---------|---------|
| Počet jasových složek   | 852246  | 850944   | 857087  | 859652  | 858627  | 859135  |
| <b>Míry polohy</b>      |         |          |         |         |         |         |
| Maximum                 | 254     | 120      | 208     | 201     | 179     | 187     |
| Horní kvartil           | 254     | 104      | 107     | 101     | 99      | 97      |
| Minimum                 | 117     | 2        | 1       | 10      | 12      | 6       |
| Dolní kvartil           | 254     | 81       | 75      | 75      | 75      | 74      |
| Průměr                  | 253,8   | 91,3     | 91,5    | 88,6    | 87,4    | 86,2    |
| Medián                  | 254     | 94       | 91      | 88      | 87      | 86      |
| <b>Míry variability</b> |         |          |         |         |         |         |
| Směrodatná odchylka     | 2,1     | 17,2     | 23,4    | 19,1    | 18,0    | 16,9    |
| Variační koeficient (%) | 0,8     | 18,8     | 25,6    | 21,6    | 20,6    | 19,6    |

Tabulka 6 deskriptivně popisuje všechny regiony vždy pro jeden časový úsek, opět je zde lineární změna u hodnot mediánu, avšak u Tabulky 5 dochází k jeho růstu, zde dochází k poklesu, stejně tak u průměru. Naopak variační koeficient i směrodatná odchylka se oproti hodnotám v Tabulce 5 pohybují v nižších hodnotách.

## 11.4 Statistická analýza druhé série měření pro region 1

Statistická analýza zahrnuje deskriptivní statistiku, popsanou v Tabulce 7, dále dvou a vícevýběrové charakteristiky.

Tabulka 7: Deskriptivní statistické údaje pro region 1 ve druhé sérii měření

|                         | 0 minut | 24 hodin | 1 týden | 2 týdny | 3 týdny | 4 týdny |
|-------------------------|---------|----------|---------|---------|---------|---------|
| Počet jasových složek   | 974     | 430229   | 578361  | 545688  | 579115  | 519173  |
| <b>Míry polohy</b>      |         |          |         |         |         |         |
| Maximum                 | 254     | 120      | 188     | 170     | 161     | 162     |
| Horní kvartil           | 254     | 97       | 100     | 95      | 94      | 91      |
| Minimum                 | 117     | 2        | 1       | 10      | 12      | 6       |
| Dolní kvartil           | 253     | 74       | 71      | 71      | 71      | 70      |
| Průměr                  | 250,7   | 84,8     | 85,9    | 83,4    | 82,9    | 81,2    |
| Medián                  | 254     | 87       | 85      | 83      | 82      | 80      |
| <b>Míry variability</b> |         |          |         |         |         |         |
| Směrodatná odchylka     | 14,2    | 17,2     | 21,8    | 17,8    | 16,9    | 15,9    |
| Variační koeficient (%) | 5,7     | 20,3     | 25,4    | 21,3    | 20,4    | 19,6    |


V Tabulce 7 můžeme pozorovat lineárně klesající závislost pro hodnoty mediánu, průměrně se hodnoty pohybují v rozmezí od 250,7 do 81,2. Maximální hodnota jasu je 254, minimální 1, takže lze soudit, že v regionu 1 v rámci všech časových úseků je zastoupena celá škála jasových hodnot. Míry variability se pohybují v nižších hodnotách.

### 11.4.1 Dvouvýběrové charakteristiky pro region 1

Pro možnost použití dvouvýběrových testů o shodě rozptylu a shodě středních hodnot, respektive mediánů je potřeba u všech dat ověřit, zdali jsou data distribucí z normálního rozložení, či nikoli.

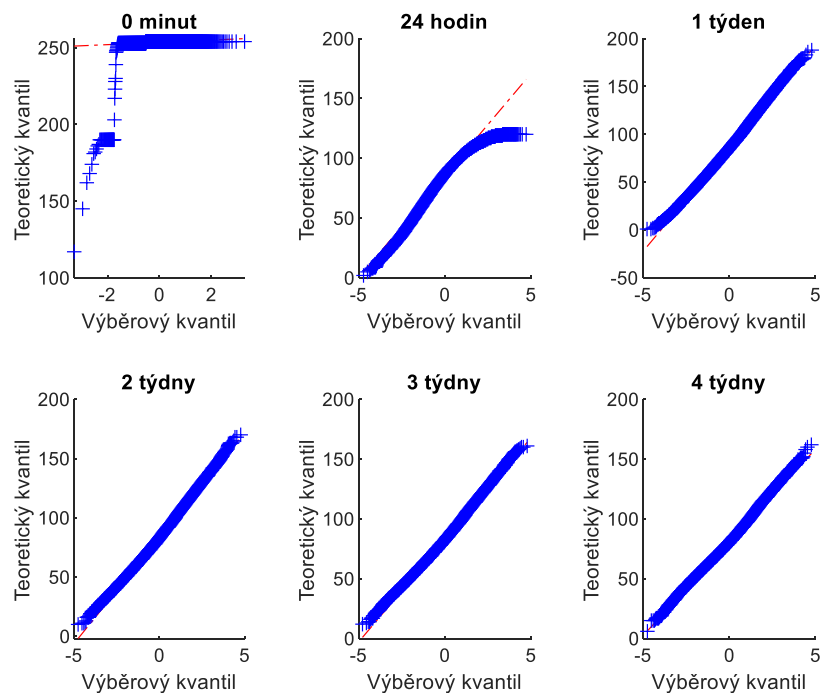
Jednotlivé jasové hodnoty byly vyneseny do boxplotů (Obrázek 59), na nichž je patrná přítomnost odlehklých pozorování. Vzhledem k povaze dat lze soudit, že se nejedná o hrubé chyby, které

by vznikly při měření, a proto nebudou z další analýzy odstraněny. První boxplot reprezentuje region 1 v čase  $t = 0$ , druhý po 1 týdnu, dále 2, 3 a 4 týden a jako poslední 24 hodin. Zajímavé je, že žádná z jasových složek u snímku za 24 hodin nedosahuje hodnot vyšších než 120.




Obrázek 59: Boxploty pro region 1 – 0 minut, 1, 2, 3 a 4 týdny a 24 hodin

Na Obrázku 60 jsou znázorněny QQ grafy pro jednotlivé distribuce v čase regionu 1. Data vypadají, že by mohla pocházet z normálního rozdělení, nicméně množství dat, které jsou na grafu znázorněny může informaci značně zkreslit, pro ověření informace se dále provádějí testy k ověření normality.



Obrázek 60: QQ grafy pro region 1 z druhé série měření

Obrázek 61 zobrazuje histogramy z jednotlivých distribucí v regionu 1.



Obrázek 61: Histogramy pro region 1 za 0 minut, 24 hodin, 1, 2, 3 a 4 týdny

Pro ověření normality byl použit Kolmogorův-Smirnovův test a na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 1 pocházejí z normálního rozložení.

$H_A: \neg H_0$

Tabulka 8: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 1

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 1 týden  | $<<0,001$ | zamítnutí $H_0$ |
| 2 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 3 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 4 týdny  | $<<0,001$ | zamítnutí $H_0$ |

Na základě Kolmogorova-Smirnova testu je na hladině významnosti 5 % zamítnuta normalita u všech zkoumaných dat (p-hodnoty jsou  $<<0,001$ ). Výsledky jsou uvedeny v Tabulce 8.

Ačkoliv je distribuce dat na QQ grafech velmi nakloněná k normálnímu rozložení, test pro ověření normality ho zamítá. Pro kontrolu byl proveden Anderson-Darlingův test pro ověření normality dat. I on zamítl nulovou hypotézu, že data pocházejí z normálního rozdělení, pro další analýzy je již používán pouze Kolmogorův-Smirnovův test.

Pro ověření homoskedasticity byl použit Levenův test a byla definována základní nulová a alternativní hypotéza:

$$H_0: \sigma_{1...6}^2 = \sigma_{1...6}^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní hypotézy, všechna rozdělení nemají stejný rozptyl, tedy jsou heteroskedastické. Tento rozdíl lze označit za statisticky významný.

Jelikož se jedná o data bez normálního rozdělení je pro zjištění shody středních hodnot, respektive mediánů použit oboustranný Wilcoxonův test součtu, který je ekvivalentním k Mannu-Whitneyovu testu pro ověření shody středních hodnot, resp. mediánů, který by byl vzhledem ke zjišťovaným parametrům použit. Mannův-Whitneyův test není součástí toolboxu v Matlabu, proto je použit test ekvivalentní. Pro další popis je použit název Mannův-Whitneyův test. Jsou definovány hypotézy:

$$H_0: x_{0,5_{1...6}} = x_{0,5_{1...6}}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, mediány jasových hodnot si nejsou rovny. Veškeré hodnoty specifikuje Tabulka 9.

Tabulka 9: Dvouvýběrové charakteristiky pro region 1 ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí      | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí      |
|---------|---------------------------|-----------------|--|-----------------|
| 0 a 24  | $4,91 \cdot 10^{-133}$    | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 1   | $1,06 \cdot 10^{-163}$    | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 2   | $2,83 \cdot 10^{-134}$    | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 3   | $1,17 \cdot 10^{-122}$    | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 4   | $8,08 \cdot 10^{-107}$    | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 1  | $<<0,001$                 | zamítnutí $H_0$ | 0,0020                                 | zamítnutí $H_0$ |
| 24 a 2  | $4,03 \cdot 10^{-80}$     | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 3  | $1,83 \cdot 10^{-66}$     | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 4  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 1 a 2   | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 1 a 3   | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 1 a 4   | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |



|       |                       |                 |           |                 |
|-------|-----------------------|-----------------|-----------|-----------------|
| 2 a 3 | $1,67 \cdot 10^{-28}$ | zamítnutí $H_0$ | $<<0,001$ | zamítnutí $H_0$ |
| 2 a 4 | $<<0,001$             | zamítnutí $H_0$ | $<<0,001$ | zamítnutí $H_0$ |
| 3 a 4 | $<<0,001$             | zamítnutí $H_0$ | $<<0,001$ | zamítnutí $H_0$ |

#### 11.4.2 Vícevýběrové charakteristiky pro region 1

Z důvodu zamítnuté normality viz. Tabulka 8 je pro vícevýběrové charakteristiky použit vícevýběrový Levenův test pro ověření shody rozptylů a na hladině 5 % jsou definovány hypotézy:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_6^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám předpoklad o shodě rozptylů, jasové složky nemají shodný rozptyl. (p-hodnota =  $<<0,001$ ).

Vzhledem k zamítnuté normalitě je potřeba pracovat s mediány jasových hodnot. Pro ověření shody měrných poloh byl využit Kruskal-Wallisův test. Používá se, pokud data nelze normalizovat a pokud nejsou data vyvážená a je porušena homoskedasticita. Na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_6}$$

$$H_A: \neg H_0$$

Tabulka 10: Kruskal-Wallisův test pro region 1

|                   | Součet čtverců       | Stupně volnosti | Průměr čtverců       | Chí-kvadrát | P-hodnota |
|-------------------|----------------------|-----------------|----------------------|-------------|-----------|
| Skupinový faktor  | $1,60 \cdot 10^{16}$ | 5               | $3,21 \cdot 10^{15}$ | 27314,63    | $<<0,001$ |
| Reziduální faktor | $1,54 \cdot 10^{18}$ | 2653534         | $5,81 \cdot 10^{11}$ | -           | -         |
| Celkem            | $1,56 \cdot 10^{18}$ | 2653539         | -                    | -           | -         |

Na hladině významnosti 5 % zamítám nulovou hypotézu, alespoň u jedné skupiny se mediány nerovnají. Výsledky jsou uvedeny v Tabulce 10. Pro další analýzu je provedena post-hoc analýza metodou Dunnové. Díky post-hoc analýze je patrné, že u všech šesti zkoumaných skupin se mediány liší (p-hodnoty =  $<<0,001$ ). Výsledky jsou díky velkému objemu dat k nahlédnutí v příloze (Tab. 1).

## 11.5 Statistická analýza druhé série měření pro region 2

Deskriptivní statistické údaje uvádí Tabulka 11.

Tabulka 11: Deskriptivní statistické údaje pro region 2 ve druhé sérii měření

|                         | 0 minut | 24 hodin | 1 týden | 2 týdny | 3 týdny | 4 týdny |
|-------------------------|---------|----------|---------|---------|---------|---------|
| Počet jasových složek   | 5       | 5119     | 9619    | 28071   | 20417   | 36975   |
| <b>Míry polohy</b>      |         |          |         |         |         |         |
| Maximum                 | 248     | 119      | 163     | 154     | 150     | 148     |
| Horní kvartil           | 248     | 94       | 98      | 93      | 91      | 92      |
| Minimum                 | 206     | 20       | 9       | 32      | 29      | 24      |
| Dolní kvartil           | 234     | 82       | 82      | 79      | 79      | 79      |
| Průměr                  | 238,2   | 87,3     | 90,0    | 86,3    | 85,8    | 85,5    |
| Medián                  | 245     | 87       | 88      | 85      | 85      | 84      |
| <b>Míry variability</b> |         |          |         |         |         |         |
| Směrodatná odchylka     | 18,1    | 12,2     | 16,2    | 13,6    | 12,6    | 12,2    |
| Variační koeficient (%) | 7,6     | 13,9     | 18,0    | 15,6    | 14,7    | 14,3    |


Oproti předchozímu sledovanému regionu 1, je patrná změna hodnot maxima a minima, zatímco u regionu 1 se pohybuje maximum na hodnotě 254, u regionu 2 kleslo k 248 a minimum vzrostlo na 9 u jasových složek za 1 týden. Lze pozorovat lineární pokles u hodnot dolního kvartilu. Průměrné hodnoty se pohybují v mírně vyšších hodnotách než u hodnot průměru pro region 1, to stejné platí i pro směrodatnou odchylku a variační koeficient, což naznačuje jen málo rozptýlený soubor.

### 11.5.1 Dvouvýběrové charakteristiky pro region 2

Prvním ověřením pro možnost použití dvouvýběrových a následně i vícevýběrových testů je ověření normality dat.

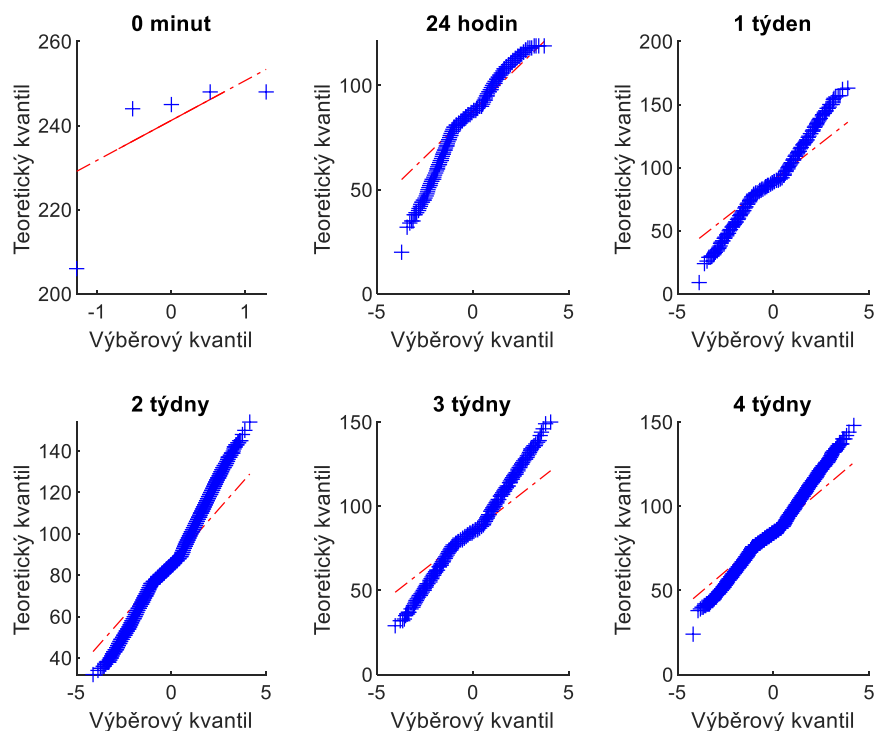
Obrázek 62 znázorňuje boxploty pro jasové ve všech měřených časech pro region 2. Zatímco u boxplotů za 1, 2, 3, 4 týdny a 24 hodin je patrný vysoký výskyt odlehlých pozorování, u regionu 2 pro

snímek vyvolaný za 0 minut je zde pouze jedno odlehlé pozorování. Může to být dáno tím, že se u času  $t = 0$  pracuje pouze s 5 hodnotami jasu.



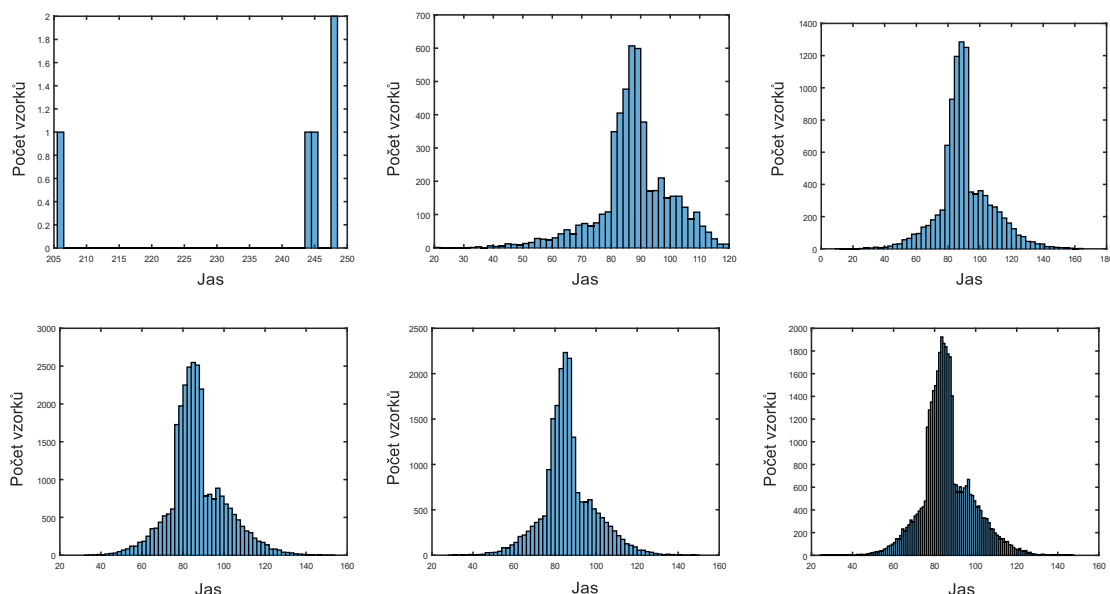
Obrázek 62: Boxploty pro region 2 – 0 minut, 1, 2, 3 a 4 týdny a 24 hodin

QQ grafy distribuce z 2 regionu demonstruje Obrázek 63. U dat je již patrný odklon od přímky, a proto zde není předpoklad normality, vše je ale ověřeno testem normality.



Obrázek 63: QQ grafy pro region 2 z druhé série měření

Obrázek 64 demonstruje histogramy pro region 2. Díky nim můžeme vidět, že data pravděpodobně nebudou z distribuce normálního rozdělení.



Obrázek 64: Histogramy pro region 2 za 0 minut, 24 hodin, 1, 2, 3 a 4 týdny

Kolmogorův-Smirnov test normality byl použit také pro všechny časy a distribuce druhého regionu zvlášť. Na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 2 pocházejí z normálního rozložení.

$H_A: \neg H_0$

Tabulka 12: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 2

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 1 týden  | $<<0,001$ | zamítnutí $H_0$ |
| 2 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 3 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 4 týdny  | $<<0,001$ | zamítnutí $H_0$ |

Na základě testu normality zamítám na hladině významnosti 5 % nulovou hypotézu u všech zkoumaných skupin, data nemají normální rozdělení (u všech skupin je p-hodnota  $<<0,001$ ). Výsledky uvádí Tabulka 12.

Z důvodu zamítnutí normality se dále pracuje s Levenovým testem pro ověření shody rozptylů. Na 5 % hladině je definována nulová a alternativní hypotéza:

$$H_0: \sigma_{1...6}^2 = \sigma_{1...6}^2$$

$$H_A: \neg H_0$$

Pracujeme se dvěma druhy výsledků: S 95% spolehlivostí lze u všech skupin, které byly testovány s daty z regionu 0 a dále u dvouvýběrového testu pro 3 a 4 region tvrdit, že jasové hodnoty mají stejný rozptyl, tudíž na hladině 5 % nezamítám nulovou hypotézu a zamítám hypotézu alternativní.

U zbylých testovaných skupin lze s 95% spolehlivostí naopak říci, že se jedná o data heteroskedasticitní a na hladině 5 % zamítám nulovou hypotézu ve prospěch alternativní hypotézy.

Pro zjištění shody středních hodnot, resp. mediánů je vzhledem k nepotvrzené normalitě dat použit Mannův-Whitneyův test, v Matlabu je počítán jako Wilcoxonův test, který je ekvivalentním. Jsou na hladině významnosti 5 % definovány hypotézy:

$$H_0: x_{0,51...6} = x_{0,51...6}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám u všech dvouvýběrových testů nulovou hypotézu, mediány si v žádné skupině nejsou rovny. Všechny výsledky testů (Levenův i Mannův-Whitneyův) uvádí Tabulka 13.

Tabulka 13: Dvouvýběrové charakteristiky pro region 2 ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí        | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí      |
|---------|---------------------------|-------------------|--|-----------------|
| 0 a 24  | 0,27                      | nezamítnutí $H_0$ | $1,07 \cdot 10^{-04}$                  | zamítnutí $H_0$ |
| 0 a 1   | 0,79                      | nezamítnutí $H_0$ | $1,07 \cdot 10^{-04}$                  | zamítnutí $H_0$ |
| 0 a 2   | 0,48                      | nezamítnutí $H_0$ | $1,07 \cdot 10^{-04}$                  | zamítnutí $H_0$ |
| 0 a 3   | 0,33                      | nezamítnutí $H_0$ | $1,07 \cdot 10^{-03}$                  | zamítnutí $H_0$ |
| 0 a 4   | 0,29                      | nezamítnutí $H_0$ | $1,07 \cdot 10^{-04}$                  | zamítnutí $H_0$ |
| 24 a 1  | $1,97 \cdot 10^{-57}$     | zamítnutí $H_0$   | $1,05 \cdot 10^{-13}$                  | zamítnutí $H_0$ |
| 24 a 2  | $1,58 \cdot 10^{-21}$     | zamítnutí $H_0$   | $4,43 \cdot 10^{-41}$                  | zamítnutí $H_0$ |
| 24 a 3  | $1,90 \cdot 10^{-3}$      | zamítnutí $H_0$   | $2,64 \cdot 10^{-54}$                  | zamítnutí $H_0$ |
| 24 a 4  | $6,20 \cdot 10^{-3}$      | zamítnutí $H_0$   | $1,01 \cdot 10^{-77}$                  | zamítnutí $H_0$ |
| 1 a 2   | $7,28 \cdot 10^{-43}$     | zamítnutí $H_0$   | $2,20 \cdot 10^{-140}$                 | zamítnutí $H_0$ |
| 1 a 3   | $1,70 \cdot 10^{-95}$     | zamítnutí $H_0$   | $7,27 \cdot 10^{-159}$                 | zamítnutí $H_0$ |
| 1 a 4   | $4,73 \cdot 10^{-138}$    | zamítnutí $H_0$   | $1,49 \cdot 10^{-221}$                 | zamítnutí $H_0$ |
| 2 a 3   | $3,66 \cdot 10^{-27}$     | zamítnutí $H_0$   | 0,04                                   | zamítnutí $H_0$ |
| 2 a 4   | $1,54 \cdot 10^{-46}$     | zamítnutí $H_0$   | $8,51 \cdot 10^{-15}$                  | zamítnutí $H_0$ |
| 3 a 4   | 0,24                      | nezamítnutí $H_0$ | $2,48 \cdot 10^{-7}$                   | zamítnutí $H_0$ |

### 11.5.2 Vícevýběrové charakteristiky pro region 2

U dvouvýběrových testů byla na základě Kolmogorova-Smirnova testu zamítnuta normalita, tohoto matematického podložení využijeme při zpracovávání vícevýběrových testů. Pro ověření shody rozptylů je využit Levenův test a na hladině významnosti 5 % jsou definovány hypotézy:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_6^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám předpoklad o homoskedasticitě, jasové složky nemají shodný rozptyl. (p-hodnota = <<0,001).

Pro další analýzu je použit Kruskal-Wallisův test pro heteroskedasticitní data a jsou definovány hypotézy na hladině významnosti 5 %:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_6}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, alespoň u dvou skupin se mediány nerovnají. Výsledky jsou uvedeny v Tabulce 14.

Tabulka 14: Kruskal-Wallisův test pro region 2

|                   | Součet čtverců       | Stupně volnosti | Průměr čtverců       | Chí-kvadrát | P-hodnota              |
|-------------------|----------------------|-----------------|----------------------|-------------|------------------------|
| Skupinový faktor  | $1,60 \cdot 10^{12}$ | 5               | $2,12 \cdot 10^{11}$ | 1270,69     | $1,43 \cdot 10^{-272}$ |
| Reziduální faktor | $8,27 \cdot 10^{13}$ | 100200          | $8,25 \cdot 10^8$    | -           | -                      |
| Celkem            | $8,38 \cdot 10^{13}$ | 100205          | -                    | -           | -                      |

Pro další ověření je provedena analýza metodou Dunnové. Ta prokázala, že u všech skupin se mediány liší (p-hodnoty = <<0,001). Výsledky jsou uvedeny v příloze Tab. 2.

## 11.6 Statistická analýza druhé série měření pro region 3

Výsledky provedené deskriptivní analýzy jsou znázorněny v Tabulce 15.

Tabulka 15: Deskriptivní statistické údaje pro region 3 ve druhé sérii měření


|                         | 0 minut | 24 hodin | 1 týden | 2 týdny | 3 týdny | 4 týdny |
|-------------------------|---------|----------|---------|---------|---------|---------|
| Počet jasových složek   | 31470   | 16461    | 6718    | 28948   | 24915   | 29250   |
| <b>Míry polohy</b>      |         |          |         |         |         |         |
| Maximum                 | 254     | 120      | 171     | 161     | 152     | 148     |
| Horní kvartil           | 253     | 96       | 98      | 95      | 94      | 93      |
| Minimum                 | 190     | 26       | 23      | 29      | 29      | 35      |
| Dolní kvartil           | 253     | 86       | 86      | 83      | 83      | 81      |
| Průměr                  | 253,2   | 89,6     | 91,6    | 88,6    | 88,4    | 86,9    |
| Medián                  | 253     | 91       | 92      | 89      | 89      | 87      |
| <b>Míry variability</b> |         |          |         |         |         |         |
| Směrodatná odchylka     | 0,6     | 12,9     | 16,4    | 13,9    | 13,0    | 12,4    |
| Variační koeficient (%) | 0,2     | 14,4     | 17,9    | 15,7    | 14,7    | 14,3    |

Nejvyšší hodnota maxima je 254 u dat za 0 minut, nejnižší naopak 120 u dat za 24 hodin. Ve vypočtených datech můžeme pozorovat zvýšení hranice hodnot minima a opakující se hodnoty minima, dolního kvartilu a mediánu ve 2. a 3. týdnu. Průměrně se hodnoty pohybují, mimo hodnotu za 0 minut, která značně vybočuje u všech proměnných, v rozmezí 88,4 až 91,6. Směrodatná odchylka i variační koeficient jsou opět u všech času poměrně nízké, nejnižší hodnoty obou proměnných jsou u snímku za 0 minut, tudíž se dá říci, že se jedná o téměř nerozptýlená data.

### 11.6.1 Dvouvýběrové charakteristiky pro region 3

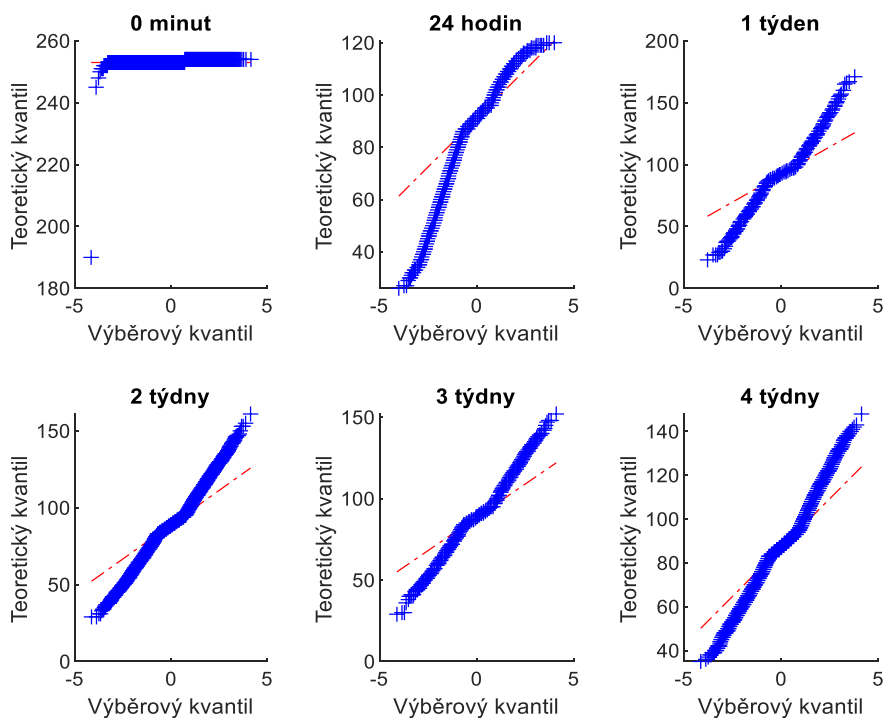
Pro ověření normality jsou opět vyneseny QQ grafy, histogramy, boxploty a proveden Kolmogorův-Smirnov test. Dále jsou provedeny dvouvýběrové testy o shodě středních hodnot.

Obrázek 65 reprezentuje boxploty pro region 3 ve všech časových úsecích. Opět je zde řada odlehlých pozorování a hodnoty v čase  $t = 0$  se výrazně liší od ostatních, jelikož se pohybují v mnohem vyšších číslech, což blíže specifikuje Tabulka 15.




Obrázek 65: Boxploty pro region 3 – 0 minut, 1, 2, 3 a 4 týdny a 24 hodin

Díky QQ grafům na Obrázku 66 je patrné, že se s největší pravděpodobností nebude jednat o normální distribuci dat. Hodnoty se značně odchylují od přímky ve všech časových úsecích. Tento předpoklad potvrzují také histogramy na Obrázku 67.



Obrázek 66: QQ grafy pro region 3 ze druhé série měření





Obrázek 67: Histogramy pro region 3 ve druhé sérii měření

Pro ověření předpokladů z QQ grafů a histogramů, že data nemají normální rozložení je použit Kolmogorův-Smirnovův test a na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 3 pocházejí z normálního rozložení.

$H_A: \neg H_0$

Tabulka 16: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 3

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 1 týden  | $<<0,001$ | zamítnutí $H_0$ |
| 2 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 3 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 4 týdny  | $<<0,001$ | zamítnutí $H_0$ |

Na hladině významnosti 5 % zamítám u všech testovaných skupin nulovou hypotézu, data nepocházejí z normálního rozložení. Výsledky dokládá Tabulka 16.

Z důvodu zamítnuté normality je pro zjištění homoskedasticity použit Levenův test a na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$H_0: \sigma_{1...6}^2 = \sigma_{1...6}^2$

$H_A: \neg H_0$

S 95% spolehlivostí lze říci, že data z dvouvýběrového Levenova testu skupiny za 24 hodin a 3 týdny jsou, jako jedná z testovaných, homoskedasticitní. Na hladině významnosti u skupiny 24 a 3 nezamítám nulovou hypotézu. U ostatních skupin lze s 95% spolehlivostí naopak říci, že jsou heteroskedasticitní a na hladině významnosti 5 % zamítám nulovou hypotézu.

Díky zamítnuté normalitě se postupuje jako u předchozího testování pro region 1 a 2. Pro ověření shody měrných poloh je využit Mannův-Whitneyův test a na hladině významnosti 5 % jsou definovány hypotézy:

$$H_0: H_0: x_{0,5_{1...6}} = x_{0,5_{1...6}}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % nezamítám nulovou hypotézu u jediné skupiny 2 a 3 a zamítám hypotézu alternativní. U ostatních skupin lze s 95% spolehlivostí říci, že se jedná o heteroskedasticitní data a na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní. Výsledky dokládá Tabulka 17.

Tabulka 17: Dvouvýběrové charakteristiky pro region 3 ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí        | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí        |
|---------|---------------------------|-------------------|--|-------------------|
| 0 a 24  | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$   |
| 0 a 1   | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$   |
| 0 a 2   | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$   |
| 0 a 3   | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$   |
| 0 a 4   | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$   |
| 24 a 1  | $1,28 \cdot 10^{-43}$     | zamítnutí $H_0$   | $1,90 \cdot 10^{-18}$                  | zamítnutí $H_0$   |
| 24 a 2  | $7,39 \cdot 10^{-19}$     | zamítnutí $H_0$   | $4,16 \cdot 10^{-88}$                  | zamítnutí $H_0$   |
| 24 a 3  | 0,67                      | nezamítnutí $H_0$ | $2,06 \cdot 10^{-104}$                 | zamítnutí $H_0$   |
| 24 a 4  | $1,34 \cdot 10^{-05}$     | zamítnutí $H_0$   | $1,72 \cdot 10^{-292}$                 | zamítnutí $H_0$   |
| 1 a 2   | $7,73 \cdot 10^{-18}$     | zamítnutí $H_0$   | $4,19 \cdot 10^{-103}$                 | zamítnutí $H_0$   |
| 1 a 3   | $3,14 \cdot 10^{-48}$     | zamítnutí $H_0$   | $1,92 \cdot 10^{-118}$                 | zamítnutí $H_0$   |
| 1 a 4   | $2,41 \cdot 10^{-79}$     | zamítnutí $H_0$   | $6,89 \cdot 10^{-79}$                  | zamítnutí $H_0$   |
| 2 a 3   | $9,82 \cdot 10^{-22}$     | zamítnutí $H_0$   | 0,36                                   | nezamítnutí $H_0$ |
| 2 a 4   | $1,49 \cdot 10^{-55}$     | zamítnutí $H_0$   | $2,12 \cdot 10^{-67}$                  | zamítnutí $H_0$   |
| 3 a 4   | $6,73 \cdot 10^{-8}$      | zamítnutí $H_0$   | $1,63 \cdot 10^{-61}$                  | zamítnutí $H_0$   |

### 11.6.2 Vícevýběrové charakteristiky pro region 3

Pro vícevýběrové testy je nutné ověřit normalitu dat, ta byla u dvouvýběrových testů zamítnuta, tudíž se pro ověření shody rozptylů vícevýběrových dat použije opět Levenův test. Na hladině 5 % je definována nulová a alternativní hypotéza:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_6^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám předpoklad o homoskedasticitě, data jsou s 95% spolehlivostí heteroskedasticitní. (p-hodnota = <<0,001)

Ověření shody měrných poloh je realizováno Kruskal-Wallisovým testem a jsou definovány hypotézy na hladině 5 %:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_6}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, alespoň u jedné skupiny dat se mediány nerovnají. Výsledky ukazuje Tabulka 18.

Tabulka 18: Kruskal-Wallisův test pro region 3

|                      | Součet<br>čtverců    | Stupně<br>volnosti | Průměr<br>čtverců    | Chí-kvadrát | P-hodnota |
|----------------------|----------------------|--------------------|----------------------|-------------|-----------|
| Skupinový<br>faktor  | $1,17 \cdot 10^{14}$ | 5                  | $2,34 \cdot 10^{13}$ | 74428,51    | <<0,001   |
| Reziduální<br>faktor | $9,96 \cdot 10^{13}$ | 137756             | $7,23 \cdot 10^8$    | -           | -         |
| Celkem               | $2,17 \cdot 10^{14}$ | 137761             | -                    | -           | -         |

Pro bližší specifikaci skupin, je provedena post-hoc analýza metodou Dunnové z níž bylo zjištěno, že mediány jasových hodnot se ve všech testovaných skupinách od sebe liší (p-hodnoty = <<0,001). Výsledky jsou doloženy v příloze v Tab. 3.

## 11.7 Statistická analýza druhé série měření pro region 4

Statistická analýza pro region 4 je uvedena v Tabulce 19, je zde absence hodnot pro snímek za 0 minut, jelikož neobsahoval žádnou jasovou složku.

Tabulka 19: Deskriptivní statistické údaje pro region 4 ve druhé sérii měření


|                         | 0 minut | 24 hodin | 1 týden | 2 týdny | 3 týdny | 4 týdny |
|-------------------------|---------|----------|---------|---------|---------|---------|
| Počet jasových složek   | 0       | 28192    | 11537   | 40909   | 74471   | 180109  |
| <b>Míry polohy</b>      |         |          |         |         |         |         |
| Maximum                 | -       | 120      | 175     | 160     | 167     | 160     |
| Horní kvartil           | -       | 99       | 103     | 100     | 101     | 101     |
| Minimum                 | -       | 20       | 20      | 24      | 25      | 26      |
| Dolní kvartil           | -       | 86       | 86      | 84      | 85      | 84      |
| Průměr                  | -       | 91,3     | 94,5    | 92,0    | 92,4    | 92,3    |
| Medián                  | -       | 94       | 97      | 94      | 94      | 93      |
| <b>Míry variability</b> |         |          |         |         |         |         |
| Směrodatná odchylka     | -       | 12,9     | 16,8    | 13,9    | 13,6    | 13,8    |
| Variační koeficient (%) | -       | 14,1     | 17,8    | 15,1    | 14,7    | 14,9    |

Lineární růst můžeme vidět u hodnot minima, které jsou ve srovnání s ostatními regiony poměrně vysoké a pohybují se od 20 do 26. U hodnot horního a dolního kvartilu je patrné, že nedochází k jejich výkyvům a pořád se drží na obdobné hranici v rozmezí u horního kvartilu 99-103, u dolního pak 84-86. U mediánu se ve třech případech opakuje hodnota 94. Směrodatná odchylka i variační koeficient nabývají poměrně nízkých hodnot, dá se tedy hovořit o mírně rozptýleném souboru.

### 11.7.1 Dvouvýběrové charakteristiky pro region 4

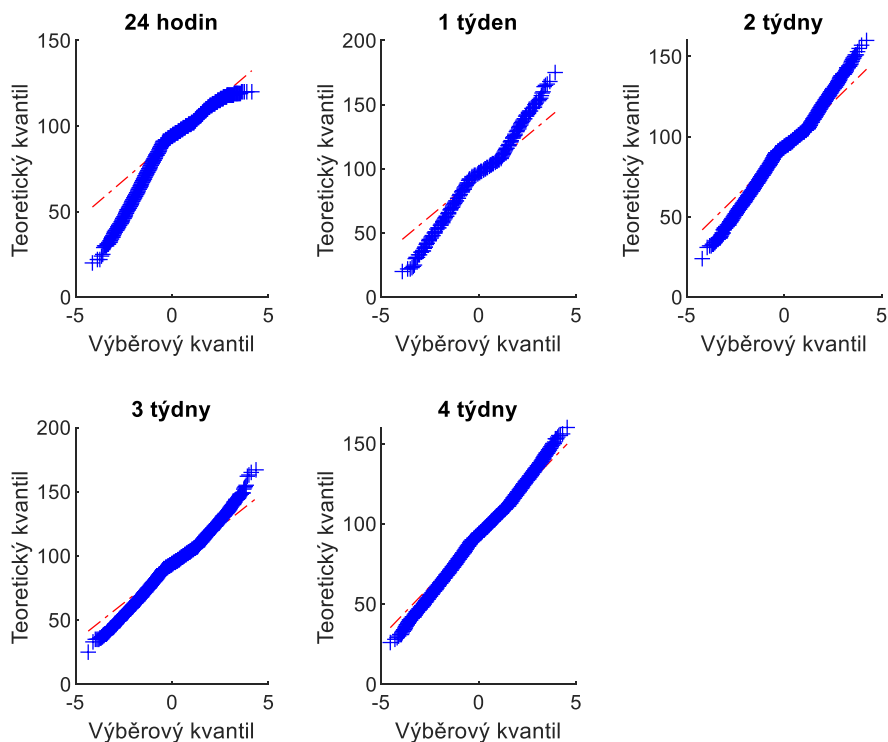
Ověření normality se provádí jako u předešlých testovaných skupin, tudíž prostřednictvím QQ grafů, hisotogramů a následně Kolmogorovovým-Smirnovým testem.

Na Obrázku 68 jsou znázorněny boxploty s odlehlými hodnotami, všechna data a jejich maxima, minima, horní a dolní kvartily jsou na podobných úrovních.




Obrázek 68: Boxploty pro region 4 – 1, 2, 3 a 4 týdny a 24 hodin

QQ grafy, Obrázek 69, vypadají pro 24 hodin a 1 týden, že pravděpodobně nebudou pocházet z normálního rozložení, jelikož se značně odchyľují od přímky, u ostatních distribucí není normalita z vizuálního hlediska patrná.



Obrázek 69: QQ grafy pro region 4 pro druhou sérii měření

Na Obrázku 70 jsou uvedeny histogramy distribucí pro region 4, na nichž je již patrné, že data nebudou pravděpodobně pocházet z normálního rozložení, jelikož obsahují viditelné výchylky od Gaussovské křivky.



Obrázek 70: Histogramy pro region 4 ve druhé sérii měření

Pro ověření normality byl použit Kolmogorův-Smirnovův test a na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 4 pocházejí z normálního rozložení.

$H_A: \neg H_0$

Tabulka 20: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 4

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 1 týden  | $<<0,001$ | zamítnutí $H_0$ |
| 2 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 3 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 4 týdny  | $<<0,001$ | zamítnutí $H_0$ |

Na základě Kolmogorova-Smirnova testu zamítám na hladině významnosti 5 % u všech testovaných skupin normalitu, data ze všech skupin nepocházejí z normálního rozložení (Tabulka 20).

Pro ověření homoskedasticity (normalita je zamítnutá) byl použit Levenův test pro ověření rozptylu. Jsou definovány hypotézy na hladině významnosti 5 %:

$$H_0: \sigma_{1...5}^2 = \sigma_{1...5}^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % nezamítám nulovou hypotézu u skupiny pro 2. a 3. týden ( $p$ -hodnota = 0,29), tato skupina je homoskedasticitní. U ostatních skupin se však nulová hypotéza na hladině 5 % zamítá a s 95% spolehlivostí lze říci, že u všech ostatních skupin jsou data heteroskedasticitní. Vše dokládá Tabulka 21.

Vzhledem k zamítnuté normalitě se pro ověření shody měrných poloh využívá Mannův-Whitneyův test a na hladině významnosti 5 % jsou definovány hypotézy:

$$H_0: x_{0,5_{1...5}} = x_{0,5_{1...5}}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % nezamítám nulovou hypotézu u skupiny 24 a 2, mediány se u této skupině rovnají. Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní u všech ostatních skupin. Výsledky dokládá Tabulka 21.

Tabulka 21: Dvouvýběrové charakteristiky pro region 4 ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí        | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí        |
|---------|---------------------------|-------------------|--|-------------------|
| 24 a 1  | $3,87 \cdot 10^{-120}$    | zamítnutí $H_0$   | $3,49 \cdot 10^{-117}$                 | zamítnutí $H_0$   |
| 24 a 2  | $6,15 \cdot 10^{-26}$     | zamítnutí $H_0$   | 0,91                                   | nezamítnutí $H_0$ |
| 24 a 3  | $6,86 \cdot 10^{-28}$     | zamítnutí $H_0$   | $4,38 \cdot 10^{-5}$                   | zamítnutí $H_0$   |
| 24 a 4  | $3,40 \cdot 10^{-85}$     | zamítnutí $H_0$   | $8,92 \cdot 10^{-3}$                   | zamítnutí $H_0$   |
| 1 a 2   | $2,15 \cdot 10^{-63}$     | zamítnutí $H_0$   | $1,33 \cdot 10^{-104}$                 | zamítnutí $H_0$   |
| 1 a 3   | $1,19 \cdot 10^{-48}$     | zamítnutí $H_0$   | $2,57 \cdot 10^{-87}$                  | zamítnutí $H_0$   |
| 1 a 4   | $4,31 \cdot 10^{-60}$     | zamítnutí $H_0$   | $1,29 \cdot 10^{-91}$                  | zamítnutí $H_0$   |
| 2 a 3   | 0,29                      | nezamítnutí $H_0$ | $1,33 \cdot 10^{-5}$                   | zamítnutí $H_0$   |
| 2 a 4   | $3,25 \cdot 10^{-13}$     | zamítnutí $H_0$   | 0,02                                   | zamítnutí $H_0$   |
| 3 a 4   | $3,75 \cdot 10^{-27}$     | zamítnutí $H_0$   | $4,10 \cdot 10^{-3}$                   | zamítnutí $H_0$   |

### 11.7.2 Více výběrové charakteristiky pro region 4

V předchozím testování byla u dat zamítnuta normalita, proto je pro ověření homoskedasticity u vícevýběrových testů použit opět Levenův test a na hladině významnosti 5 % jsou definovány hypotézy:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_5^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, a tudíž i předpoklad o homoskedasticitě. (p-hodnota =  $\ll 0,001$ ).

Pro ověření shody měrných poloh byl využit Kruskal-Wallisův test a na hladině významnosti 5% je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_5}$$

$$H_A: \neg H_0$$

Tabulka 22: Kruskal-Wallisův test pro region 4

|                   | Součet čtverců       | Stupně volnosti | Průměr čtverců       | Chí-kvadrát | P-hodnota              |
|-------------------|----------------------|-----------------|----------------------|-------------|------------------------|
| Skupinový faktor  | $4,65 \cdot 10^2$    | 4               | $1,16 \cdot 10^{12}$ | 496,44      | $3,94 \cdot 10^{-106}$ |
| Reziduální faktor | $3,13 \cdot 10^{15}$ | 335213          | $9,34 \cdot 10^9$    | -           | -                      |
| Celkem            | $3,14 \cdot 10^{15}$ | 335217          | -                    | -           | -                      |

Na hladině významnosti 5 % zamítám nulovou hypotézu, ve prospěch alternativní, alespoň u dvou skupin si mediány nejsou rovny, výsledky jsou uvedeny v Tabulka 22. Pro další zpracování a bližší specifikaci je provedena post-hoc analýza metodou Dunnové, jejíž výsledky jsou uvedeny v příloze Tab. 4. Z výsledků lze říct, že se všechny mediány od sebe významně liší.



## 11.8 Statistická analýza druhé série měření pro region 5

Deskriptivní statistiku pro region 5 ve všech časových úsecích vidíme v Tabulce 23.

Tabulka 23: Deskriptivní statistické údaje pro region 5 ve druhé sérii měření

|                         | 0 minut | 24 hodin | 1 týden | 2 týdny | 3 týdny | 4 týdny |
|-------------------------|---------|----------|---------|---------|---------|---------|
| Počet jasových složek   | 819797  | 370943   | 250852  | 216036  | 159709  | 93628   |
| <b>Míry polohy</b>      |         |          |         |         |         |         |
| Maximum                 | 254     | 120      | 208     | 201     | 197     | 187     |
| Horní kvartil           | 254     | 109      | 119     | 113     | 113     | 114     |
| Minimum                 | 190     | 12       | 1       | 22      | 24      | 27      |
| Dolní kvartil           | 254     | 92       | 90      | 89      | 90      | 89      |
| Průměr                  | 253,8   | 99,1     | 104,3   | 101,4   | 101,2   | 101,9   |
| Medián                  | 254     | 102      | 105     | 102     | 102     | 102     |
| <b>Míry variability</b> |         |          |         |         |         |         |
| Směrodatná odchylka     | 2,0     | 14,4     | 22,5    | 18,4    | 17,6    | 17,8    |
| Variační koeficient (%) | 0,8     | 21,6     | 21,6    | 18,1    | 17,4    | 17,4    |


V deskriptivních statistických údajích pro region 5 není viditelná žádná linearita ve vypočtených hodnotách. Nejvyšších hodnot maxima, minima, horního i dolního kvartilu, průměru a mediánu dosahuje pro region 5 snímek, vyvolaný za 0 minut. U nějž je však patrná nejnižší hodnota směrodatné odchylky i variačního koeficientu, z čehož jde soudit, že jsou v souboru velmi málo rozptýlená data.

### 11.8.1 Dvouvýběrové charakteristiky pro region 5

Pro zhodnocení povahy dat jsou vyneseny boxploty, QQ grafy, histogramy a prostřednictvím těchto grafických prezentací dat je vizuálně ověřena normalita dat.

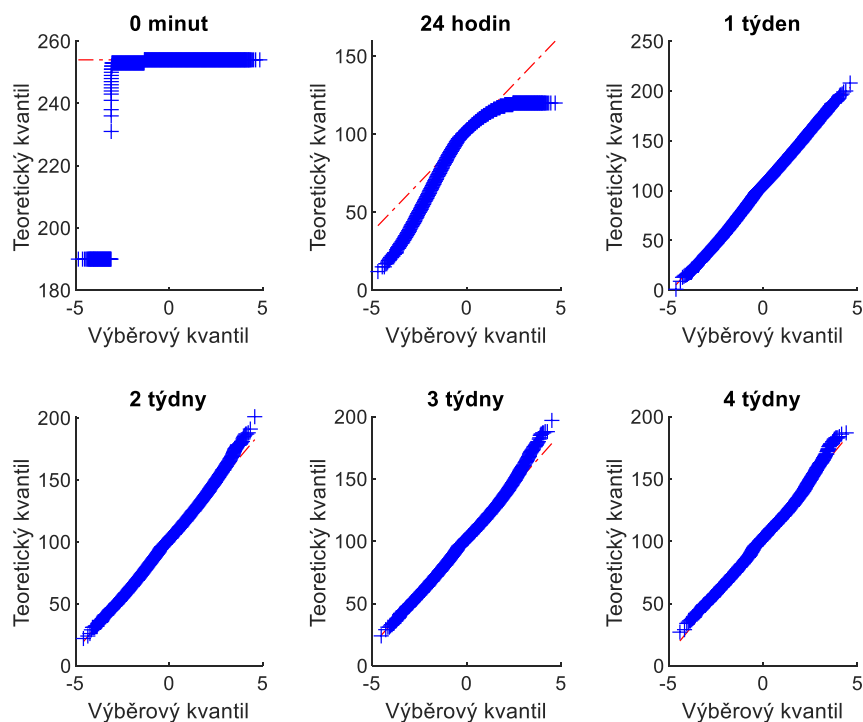
Boxploty na Obrázku 71 znázorňují, tak jako i ve všech ostatních případech, přítomnost odlehlých pozorování. Je ale potřeba zmínit, že jsou ve všech regionech krabice, a tudíž jejichž interkvartilové rozpětí s výjimkou času  $t = 0$  minut souměrné. U času  $t = 24$  hodin je patrný výskyt

odlehklých pozorování pouze v dolní hranici a nad maximem 120 se již žádné odlehlé pozorování nevyskytuje.




Obrázek 71: Boxploty pro region 5 – 0 minut, 1, 2, 3 a 4 týdny a 24 hodin

Na Obrázku 72 jsou znázorněny QQ grafy pro jednotlivé distribuce v čase regionu 5. Data za 1, 2, 3 a 4 týdny vypadají, že by pravděpodobně mohla pocházet z normální distribuce. U dat za 0 minut a 24 hodin se normální distribuce nepředpokládá.



Obrázek 72: QQ grafy pro region 5 ve druhé sérii měření

Obrázek 73 demonstruje histogramy pro region 5. Jsou zde patrné výkyvy u všech exponovaných skupin, tudíž předpoklad, že se opravdu jedná o data z normálního rozdělení bude s velkou pravděpodobností zamítnut. Vše se ověří také matematicky.



Obrázek 73: Histogramy pro region 5 ve druhé sérii měření

Pro ověření, zda data opravdu pocházejí z normální distribuce byl použit Kolmogorův-Smirnovův test a na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 5 pocházejí z normálního rozdělení.

$H_A: \neg H_0$

Tabulka 24: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 5

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 1 týden  | $<<0,001$ | zamítnutí $H_0$ |
| 2 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 3 týdny  | $<<0,001$ | zamítnutí $H_0$ |
| 4 týdny  | $<<0,001$ | zamítnutí $H_0$ |

Na hladině významnosti 5 % zamítám nulovou hypotézu, ani jedna skupina dat nepochází z distribuce s normálním rozdělením. Výsledky jsou doloženy v Tabulka 24. S tímto faktem zamítnuté normality se bude dál postupovat a bude stěžejním pro výběr dalších testů.

Pro ověření homoskedasticity byl použit Levenův test a na hladině 5 % byla definována nulová a alternativní hypotéza:

$$H_0: \sigma_{1...6}^2 = \sigma_{1...6}^2$$

$$H_A: \neq H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní hypotézy, všechny testované skupiny nemají stejný rozptyl. S 95% spolehlivostí lze data označit za heteroskedasticitní. Tento rozdíl lze označit za statisticky významný.

Jelikož se jedná o data bez normálního rozdělení je pro zjištění shody středních hodnot, respektive mediánů použit Mannův-Whitneyův test a na hladině významnosti 5 % jsou definovány hypotézy:

$$H_0: x_{0,5_{1...6}} = x_{0,5_{1...6}}$$

$$H_A: \neq H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, mediány jasových hodnot si nejsou rovny. Veškeré hodnoty výsledků pro Levenův i Mannův-Whitneyův test specifikuje Tabulka 25.

*Tabulka 25: Dvouvýběrové charakteristiky pro region 5 ve všech kombinacích*

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí      | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí      |
|---------|---------------------------|-----------------|--|-----------------|
| 0 a 24  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 1   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 2   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 3   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 4   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 24 a 1  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 24 a 2  | <<0,001                   | zamítnutí $H_0$ | $5,57 \cdot 10^{-223}$                 | zamítnutí $H_0$ |
| 24 a 3  | <<0,001                   | zamítnutí $H_0$ | $5,83 \cdot 10^{-145}$                 | zamítnutí $H_0$ |
| 24 a 4  | <<0,001                   | zamítnutí $H_0$ | $5,62 \cdot 10^{-257}$                 | zamítnutí $H_0$ |
| 1 a 2   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 1 a 3   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 1 a 4   | <<0,001                   | zamítnutí $H_0$ | $9,66 \cdot 10^{-278}$                 | zamítnutí $H_0$ |
| 2 a 3   | $3,62 \cdot 10^{-65}$     | zamítnutí $H_0$ | 0,01                                   | zamítnutí $H_0$ |
| 2 a 4   | $1,13 \cdot 10^{-19}$     | zamítnutí $H_0$ | $2,71 \cdot 10^{-13}$                  | zamítnutí $H_0$ |
| 3 a 4   | $1,54 \cdot 10^{-20}$     | zamítnutí $H_0$ | $1,54 \cdot 10^{-20}$                  | zamítnutí $H_0$ |

### 11.8.2 Vícevýběrové charakteristiky pro region 5

Z důvodu zamítnuté normality (Tabulka 24) je pro vícevýběrové charakteristiky použit Levenův test pro ověření homoskedasticity a na hladině 5 % jsou definovány hypotézy:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_6^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám předpoklad o shodě rozptylů, jasové hodnoty lze s 95% spolehlivostí označit za heteroskedasticitní. (p-hodnota = <<0,001).

Vzhledem k zamítnuté normalitě je potřeba pracovat s mediány zkoumaných dat. Pro ověření shody měrných poloh byl využit Kruskal-Wallisův test. Na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_6}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní, alespoň u dvou zkoumaných skupin si mediány nejsou rovny. Výsledky jsou uvedeny v Tabulce 26.

Tabulka 26: Kruskal-Wallisův test pro region 5

|                   | Součet čtverců       | Stupně volnosti | Průměr čtverců       | Chí-kvadrát       | P-hodnota |
|-------------------|----------------------|-----------------|----------------------|-------------------|-----------|
| Skupinový faktor  | $4,28 \cdot 10^{17}$ | 5               | $8,57 \cdot 10^{16}$ | $1,49 \cdot 10^6$ | <<0,001   |
| Reziduální faktor | $1,19 \cdot 10^{17}$ | 1910959         | $6,23 \cdot 10^{10}$ | -                 | -         |
| Celkem            | $5,47 \cdot 10^{17}$ | 1910964         | -                    | -                 | -         |

Pro specifikaci, o které skupiny se jedná je použita post-hoc analýza metodou Dunnové, ta je uvedena v Tab. 5. Z výsledků post-hoc analýzy lze říct, že se u všech skupin mediány liší (p-hodnoty = <<0,001).

## 11.9 Deskriptivní statistické údaje pro první sérii měření

Deskriptivní statistika byla provedena také pro všechny časy v rámci jednoho regionu pro první sérii měření, aby se mohlo zhodnotit, jak moc se od sebe tato dvě měření liší a jak změna kontrastu a jasu ovlivňuje výsledné parametry. Deskriptivní statistika pro všechny časy v rámci jednoho regionu je uvedena v Tabulce 27.

Tabulka 27: Deskriptivní statistické údaje pro všechny časy v rámci jednoho regionu

| Region                  | 1       | 2      | 3      | 4      | 5       |
|-------------------------|---------|--------|--------|--------|---------|
| Počet jasových složek   | 2307311 | 266207 | 426845 | 425700 | 2435289 |
| <b>Míry polohy</b>      |         |        |        |        |         |
| Maximum                 | 254     | 248    | 254    | 220    | 254     |
| Horní kvartil           | 157     | 148    | 154    | 156    | 254     |
| Minimum                 | 9       | 60     | 49     | 56     | 41      |
| Dolní kvartil           | 131     | 136    | 140    | 145    | 160     |
| Průměr                  | 144,2   | 142,4  | 153,3  | 150,2  | 193,9   |
| Medián                  | 144     | 141    | 146    | 151    | 175     |
| <b>Míry variability</b> |         |        |        |        |         |
| Směrodatná odchylka     | 18,9    | 10,9   | 29,7   | 10,6   | 44,8    |
| Variační koeficient (%) | 13,1    | 7,7    | 19,4   | 7,1    | 23,1    |

Z dat můžeme sledovat lineárně rostoucí hodnoty dolního kvartilu jako jediné proměnné, která vykazuje určitou postupně se měnící závislost. Ostatní hodnoty již žádnou linearitu nevykazují. Ve srovnání s údaji ze druhé série měření jsou hodnoty minima i dolního kvartilu vyšší. Naopak variační koeficient v ani jednom z případů nepřekročil 50 % tak, jako ve druhé sérii měření a lze tedy tvrdit, že se jedná o málo rozptýlený soubor.

Tabulka 28: Deskriptivní statistické údaje pro všechny regiony v rámci jednoho časového úseku

|                         | 0 minut | 24 hod. | 48 hod. | 4 dny  | 8 dní  | 16 dní | 32 dní |
|-------------------------|---------|---------|---------|--------|--------|--------|--------|
| Počet jasových složek   | 855040  | 856044  | 858112  | 854035 | 767853 | 831447 | 838821 |
| <b>Míry polohy</b>      |         |         |         |        |        |        |        |
| Maximum                 | 254     | 187     | 202     | 239    | 243    | 233    | 246    |
| Horní kvartil           | 254     | 172     | 173     | 171    | 154    | 153    | 153    |
| Minimum                 | 117     | 9       | 9       | 14     | 61     | 32     | 32     |
| Dolní kvartil           | 254     | 149     | 144     | 144    | 134    | 135    | 135    |
| Průměr                  | 253,8   | 158,6   | 156,9   | 157,2  | 143,9  | 143,8  | 143,9  |
| Medián                  | 254     | 162     | 160     | 158    | 144    | 144    | 144    |
| <b>Míry variability</b> |         |         |         |        |        |        |        |
| Směrodatná odchylka     | 2,1     | 18,3    | 21,6    | 20,4   | 14,8   | 13,2   | 13,3   |
| Variační koeficient (%) | 0,8     | 11,5    | 13,8    | 12,9   | 10,3   | 9,2    | 9,2    |

Naopak u deskriptivní statistiky pro všechny regiony v rámci jednoho časového úseku (Tabulka 28) je patrná linearita u změn hodnot mediánu tak, jako i ve druhé sérii měření. Obecně se hodnoty pohybují v obou sériích měření na stejných číselných hladinách bez ohledu na to, že každé měření mělo jiné vstupní parametry.

## 11.10 Statistická analýza první série měření pro region 1

Deskriptivní statistické údaje pro region 1 v první sérii měření jsou uvedeny v Tabulce 29.

Tabulka 29: Deskriptivní statistické údaje pro region 1 v první sérii měření

|                         | 0 minut | 24 hod. | 48 hod. | 4 dny  | 8 dní  | 16 dní | 32 dní |
|-------------------------|---------|---------|---------|--------|--------|--------|--------|
| Počet jasových složek   | 860     | 390445  | 435410  | 484115 | 368784 | 311540 | 316157 |
| <b>Míry polohy</b>      |         |         |         |        |        |        |        |
| Maximum                 | 254     | 187     | 201     | 232    | 243    | 233    | 245    |
| Horní kvartil           | 254     | 165     | 164     | 164    | 147    | 144    | 144    |
| Minimum                 | 117     | 9       | 9       | 14     | 61     | 32     | 32     |
| Dolní kvartil           | 253     | 140     | 136     | 138    | 128    | 128    | 128    |
| Průměr                  | 250,2   | 151,2   | 148,9   | 150,6  | 137,2  | 135,7  | 135,9  |
| Medián                  | 254     | 154     | 151     | 151    | 137    | 135    | 135    |
| <b>Míry variability</b> |         |         |         |        |        |        |        |
| Směrodatná odchylka     | 15,1    | 19,1    | 21,6    | 19,9   | 14,1   | 12,2   | 12,3   |
| Variační koeficient (%) | 6,0     | 12,6    | 14,5    | 13,2   | 10,3   | 8,9    | 9,1    |


V regionu 1 jak pro první, tak i pro druhou sérii měření je patrná lineárně klesající hodnota mediánu, ta se u první série pohybuje v rozmezí od 254 do 135. Nejméně hodnot jasových složek obsahuje snímek vyvolaný za 0 minut, je to právě z důvodu toho, že na něj nestihla přírodní radiace působit a zanechat dostatečnou jasovou stopu. Míry variability se pohybují v poměrně nízkých hodnotách a lze soudit, že se opět nejedná o příliš rozptýlený soubor.

### 11.10.1 Dvouvýběrové charakteristiky pro region 1

Užití dvouvýběrových testů zahrnuje v prvním kroku testování normality dat. Testování normality je možné několika způsoby ať už vizuálním nebo matematickým. Jasové hodnoty regionu 1 byly pro všechny časy vyneseny do boxplotů (Obrázek 74). Na uvedených boxplotech můžeme opět

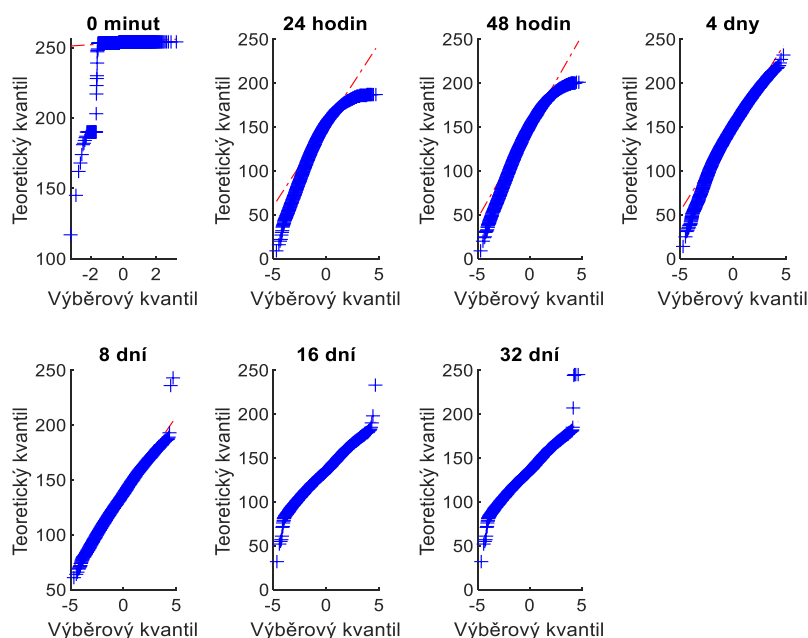


pozorovat velké množství odlehlých pozorování, které nejsou z datového souboru vyloučeny z toho důvodu, že se nejedná o hrubé chyby, ale jasové hodnoty spadající do obrazu a bez nich by mohlo dojít ke zkreslení výsledků.




Obrázek 74: Boxploty pro region 1 – 0 minut, 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin

Příslušné QQ grafy reprezentuje Obrázek 75. Vzhledem k předchozím QQ grafů, pro různé regiony se již normalita dat nepředpokládá, neboť je na první pohled zřejmé, že ve všech případech dochází k výchylkám od přímky, která data prokládá.



Obrázek 75: QQ grafy pro region 1 v první sérii měření

Pro posouzení jsou zde uvedeny také histogramy (Obrázek 76). Všechny uvedené histogramy vykazují značné špičky a normalita dat se tudíž opět nepředpokládá.



Obrázek 76: Histogramy pro region 1 v první sérii měření

Pro ověření, zda data pocházejí z normální distribuce byl použit Kolmogorův-Smirnovův test a na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 1 pocházejí z normálního rozložení.

$H_A: \neg H_0$

Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní, data žádné skupiny nepocházejí z distribuce s normálním rozložením. Výsledky uvádí Tabulka 30.

Tabulka 30: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 1

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 48 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 4 dny    | $<<0,001$ | zamítnutí $H_0$ |
| 8 dní    | $<<0,001$ | zamítnutí $H_0$ |
| 16 dní   | $<<0,001$ | zamítnutí $H_0$ |
| 32 dní   | $<<0,001$ | zamítnutí $H_0$ |

Pro další práci je vzhledem k zamítnuté normalitě použit Levenův a Mannův-Whitneyův test. Pro Levenův test je na hladině významnosti 5 % definována nulová a alternativní hypotéza:

$H_0: \sigma_{1...7}^2 = \sigma_{1...7}^2$

$H_A: \neg H_0$

Na hladině významnosti 5 % zamítám předpoklad homoskedasticity, všechny testované skupiny jsou heteroskedasticitní.

Pro ověření shody středních hodnot, resp. mediánů je použit Mannův-Whitneyův test, na hladině významnosti 5 % jsou definovány hypotézy:

$$H_0: x_{0,5_{1...7}} = x_{0,5_{1...7}}$$

$$H_A: \neq H_0$$

S 95% spolehlivostí lze říci, že si mediány ani v jedné skupině nejsou rovny a na hladině významnosti 5 % zamítám nulovou hypotézu. Výsledky testů jsou uvedeny v Tabulce 31.

Tabulka 31: Dvouvýběrové charakteristiky pro region I ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí      | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí      |
|---------|---------------------------|-----------------|--|-----------------|
| 0 a 24  | $6,59 \cdot 10^{-98}$     | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 48  | $2,24 \cdot 10^{-124}$    | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 4   | $4,31 \cdot 10^{-109}$    | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 8   | $1,20 \cdot 10^{-62}$     | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 16  | $2,62 \cdot 10^{-34}$     | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 0 a 32  | $3,40 \cdot 10^{-36}$     | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 48 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 4  | $1,96 \cdot 10^{-218}$    | zamítnutí $H_0$ | $8,97 \cdot 10^{-273}$                 | zamítnutí $H_0$ |
| 24 a 8  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 16 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 32 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 4  | $<<0,001$                 | zamítnutí $H_0$ | $1,84 \cdot 10^{-120}$                 | zamítnutí $H_0$ |
| 48 a 8  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 16 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 32 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 8   | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 16  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 32  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 8 a 16  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 8 a 32  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 16 a 32 | $4,27 \cdot 10^{-8}$      | zamítnutí $H_0$ | $3,71 \cdot 10^{-11}$                  | zamítnutí $H_0$ |

### 11.10.2 Vícevýběrové charakteristiky pro region 1

Vzhledem k zamítnuté normalitě je opět použit Levenův test. Pro vícevýběrový Levenův test jsou na hladině normality 5 % definovány hypotézy:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_7^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám předpoklad o shodě rozptylů, jasové hodnoty lze s 95% spolehlivostí označit za heteroskedasticitní. (p-hodnota = <<0,001).

Pro ověření shody měrných poloh je využit Kruskal-Wallisův test. Na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_7}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní, alespoň u dvou testovaných skupin si mediány nejsou rovny. Výsledky uvádí Tabulka 32.

Tabulka 32: Kruskal-Wallisův test pro region 1

|                   | Součet čtverců       | Stupně volnosti | Průměr čtverců        | Chí-kvadrát | P-hodnota |
|-------------------|----------------------|-----------------|-----------------------|-------------|-----------|
| Skupinový faktor  | $1,69 \cdot 10^{17}$ | 6               | $2,81 \cdot 10^{16}$  | 380159,97   | << 0,001  |
| Reziduální faktor | $8,55 \cdot 10^{17}$ | 2307304         | $93,70 \cdot 10^{11}$ | -           | -         |
| Celkem            | $1,02 \cdot 10^{18}$ | 2307310         | -                     | -           | -         |

Vzhledem k tomu, že Kruskal-Wallisův test nepotvrdil shodu mediánů, je provedena post-hoc analýza metodou Dunnové. Díky post-hoc analýze uvedené v příloze Tab. 6 je patrné, že si mediány nejsou rovny u žádné z testovaných skupin.

## 11.11 Statistická analýza první série měření pro region 2

Tabulka 33 demonstruje deskriptivní statistické údaje pro region 2 v první sérii měření.

Tabulka 33: Deskriptivní statistické údaje pro region 2 v první sérii měření


|                         | 0 minut | 24 hod. | 48 hod. | 4 dny | 8 dní | 16 dní | 32 dní |
|-------------------------|---------|---------|---------|-------|-------|--------|--------|
| Počet jasových složek   | 5       | 7432    | 10093   | 23326 | 53399 | 80859  | 91093  |
| <b>Míry polohy</b>      |         |         |         |       |       |        |        |
| Maximum                 | 248     | 187     | 199     | 227   | 186   | 178    | 178    |
| Horní kvartil           | 248     | 162     | 161     | 162   | 145   | 144    | 145    |
| Minimum                 | 206     | 79      | 60      | 64    | 76    | 93     | 93     |
| Dolní kvartil           | 235     | 149     | 146     | 147   | 135   | 135    | 135    |
| Průměr                  | 238,2   | 154,5   | 152,6   | 154,1 | 140,3 | 140,1  | 140,4  |
| Medián                  | 245     | 155     | 152     | 153   | 140   | 140    | 140    |
| <b>Míry variability</b> |         |         |         |       |       |        |        |
| Směrodatná odchylka     | 18,1    | 13,1    | 15,3    | 14,0  | 9,7   | 8,4    | 8,6    |
| Variační koeficient (%) | 7,6     | 8,5     | 10,0    | 9,1   | 6,9   | 5,9    | 6,1    |

Oproti sledované druhé sérii měření došlo v první sérii měření k zvýšení hodnot mediánu, maxima, minima s nimi vázaného horního a dolního kvartilu. Naopak směrodatná odchylka i variační koeficient jsou na rozdíl od první sledované skupiny velmi nízké.

### 11.11.1 Dvouvýběrové charakteristiky pro region 2

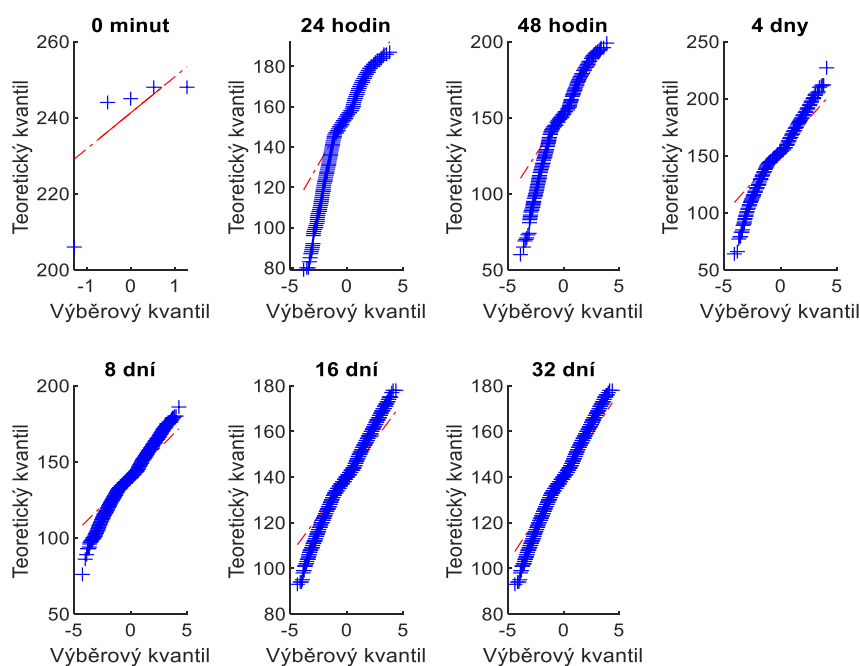
Ověření normality je provedeno QQ grafy, histogramy a matematickým výpočtem pomocí Kolmogorova-Smirnova testu.

Na Obrázku 77 jsou znázorněny boxploty pro všechny zkoumané skupiny v regionu 2. Je zde řada odlehlých pozorování, která vzhledem ke své povaze nejsou ze souboru odstraněna, jak je již zmíněno v úvodu kapitoly.




Obrázek 77: Boxploty pro region 2 – 0 minut, 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin

U QQ grafů na Obrázku 77 můžeme pozorovat, že opět dochází k odchýlení od proložené přímky, a tudíž zde není předpoklad normality.



Obrázek 78: QQ grafy pro region 2 ve druhé sérii měření

Velké výchylky a nelineární křivka jsou také patrné na histogramech (Obrázek 79).



Obrázek 79: Histogramy regionu 2 v první sérii měření

Kolmogorův-Smirnov test byl použit pro všechna data v regionu 2 v první sérii měření a na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 2 pocházejí z normálního rozložení.

$H_A: \neg H_0$

Tabulka 34: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 2

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 48 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 4 dny    | $<<0,001$ | zamítnutí $H_0$ |
| 8 dní    | $<<0,001$ | zamítnutí $H_0$ |
| 16 dní   | $<<0,001$ | zamítnutí $H_0$ |
| 32 dní   | $<<0,001$ | zamítnutí $H_0$ |

Na hladině významnosti 5 % zamítám u všech testovaných skupin nulovou hypotézu, data nejsou z normálního rozložení. Výsledky jsou uvedeny v Tabulce 34. Vzhledem k zamítnuté normalitě se pro ověření homoskedasticity využije Levenova testu a pro ověření shody mediánů Mannův-Whitneyův test.

Pro Levenův test je na hladině významnosti 5 % definována nulová a alternativní hypotéza ve znění:

$H_0: H_0: \sigma_{1...7}^2 = \sigma_{1...7}^2$

$H_A: \neg H_0$

Pracujeme se dvěma druhy výsledků. Na hladině významnosti 5 % nezamítám shodu rozptylu u párových testů regionu 0 a 24, 0 a 48, 0 a 4 a také 0 a 8. U zbylých testovaných skupin lze s 95% spolehlivostí říct, že jsou heteroskedasticitní.

Pro ověření shody středních hodnot, resp. mediánů je použit již zmíněný Mannův-Whitneyův test a jsou definovány hypotézy:

$$H_0: x_{0,5_{1...7}} = x_{0,5_{1...7}}$$

$$H_A: \neq H_0$$

U skupiny 8 a 16 je na hladině významnosti 5 % potvrzen předpoklad shody mediánů, u všech zbylých skupin je na hladině významnosti 5 % zamítnuta nulová hypotéza a nezamítnuta alternativní. U zbylých skupin si mediány nejsou rovny. Výsledky testů jsou uvedeny v Tabulce 35.

Tabulka 35: Dvouvýběrové charakteristiky pro region 2 ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí        | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí      |
|---------|---------------------------|-------------------|--|-----------------|
| 0 a 24  | 0,39                      | nezamítnutí $H_0$ | $1,07 \cdot 10^{-4}$                   | zamítnutí $H_0$ |
| 0 a 48  | 0,68                      | nezamítnutí $H_0$ | $1,07 \cdot 10^{-4}$                   | zamítnutí $H_0$ |
| 0 a 4   | 0,54                      | nezamítnutí $H_0$ | $1,07 \cdot 10^{-4}$                   | zamítnutí $H_0$ |
| 0 a 8   | 0,05                      | nezamítnutí $H_0$ | $1,06 \cdot 10^{-4}$                   | zamítnutí $H_0$ |
| 0 a 16  | 0,01                      | zamítnutí $H_0$   | $1,06 \cdot 10^{-4}$                   | zamítnutí $H_0$ |
| 0 a 32  | 0,01                      | zamítnutí $H_0$   | $1,06 \cdot 10^{-4}$                   | zamítnutí $H_0$ |
| 24 a 48 | $1,26 \cdot 10^{-25}$     | zamítnutí $H_0$   | $1,17 \cdot 10^{-45}$                  | zamítnutí $H_0$ |
| 24 a 4  | $2,81 \cdot 10^{-14}$     | zamítnutí $H_0$   | $5,29 \cdot 10^{-25}$                  | zamítnutí $H_0$ |
| 24 a 8  | $1,23 \cdot 10^{-121}$    | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 16 | $<<0,001$                 | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 32 | $<<0,001$                 | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 4  | $2,64 \cdot 10^{-8}$      | zamítnutí $H_0$   | $1,67 \cdot 10^{-12}$                  | zamítnutí $H_0$ |
| 48 a 8  | $<<0,001$                 | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 16 | $<<0,001$                 | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 32 | $<<0,001$                 | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 8   | $<<0,001$                 | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 16  | $<<0,001$                 | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 32  | $<<0,001$                 | zamítnutí $H_0$   | $<<0,001$                              | zamítnutí $H_0$ |



|         |                        |                 |                      |                   |
|---------|------------------------|-----------------|----------------------|-------------------|
| 8 a 16  | $6,01 \cdot 10^{-201}$ | zamítnutí $H_0$ | 0,24                 | nezamítnutí $H_0$ |
| 8 a 32  | $<<0,001$              | zamítnutí $H_0$ | $1,89 \cdot 10^{-4}$ | zamítnutí $H_0$   |
| 16 a 32 | $1,69 \cdot 10^{-12}$  | zamítnutí $H_0$ | $2,49 \cdot 10^{-9}$ | zamítnutí $H_0$   |

### 11.11.2 Vícevýběrové charakteristiky pro region 2

Na hladině významnosti 5 % byla u Kolmogorova-Smirnova testů zamítnuta u všech zkoumaných skupin normalita, pro ověření shody rozptylů je využit Levenův test a pro ověření shody mediánů je užit Kruskal-Wallisův test.

Na hladině významnosti 5 % je pro Levenův test definována nulová a alternativní hypotéza:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_7^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, jasové složky nemají shodný rozptyl (p-hodnota =  $<<0,001$ ).

Na hladině významnosti 5 % je pro Kruskal-Wallisův test definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_7}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní, alespoň u dvou testovaných skupin se mediány nerovnají. Výsledky uvádí Tabulka 36.

Tabulka 36: Kruskal-Wallisův test pro region 2

|                   | Součet čtverců        | Stupně volnosti | Průměr čtverců       | Chí-kvadrát | P-hodnota |
|-------------------|-----------------------|-----------------|----------------------|-------------|-----------|
| Skupinový faktor  | $42,55 \cdot 10^{14}$ | 6               | $4,25 \cdot 10^{13}$ | 43276,67    | $<<0,001$ |
| Reziduální faktor | $1,31 \cdot 10^{15}$  | 266200          | $4,94 \cdot 10^9$    | -           | -         |
| Celkem            | $1,57 \cdot 10^{15}$  | 266206          | -                    | -           | -         |

Vzhledem k zamítnutí nulové hypotézy u multitestování metodou Kruskal-Wallisova testu je provedena post-hoc analýza metodou Dunnové. Ta prokazuje, že se mediány u žádné z testovaných skupin nerovnají (p-hodnota  $<<0,001$ ). Výsledky jsou uvedeny v příloze Tab. 7.

## 11.12 Statistická analýza první série měření pro region 3

Výsledky deskriptivní analýzy jsou uvedeny v Tabulce 37.


Tabulka 37: Deskriptivní statistické údaje pro region 3 v první sérii měření

|                         | 0 minut | 24 hod. | 48 hod. | 4 dny | 8 dní | 16 dní | 32 dní |
|-------------------------|---------|---------|---------|-------|-------|--------|--------|
| Počet jasových složek   | 30628   | 14035   | 13697   | 26530 | 70220 | 135688 | 136047 |
| <b>Míry polohy</b>      |         |         |         |       |       |        |        |
| Maximum                 | 254     | 186     | 200     | 213   | 190   | 182    | 182    |
| Horní kvartil           | 253     | 163     | 162     | 163   | 149   | 149    | 149    |
| Minimum                 | 190     | 76      | 49      | 76    | 89    | 90     | 90     |
| Dolní kvartil           | 253     | 153     | 150     | 151   | 139   | 139    | 140    |
| Průměr                  | 253,2   | 156,2   | 154,9   | 156,7 | 143,6 | 143,9  | 144,1  |
| Medián                  | 253     | 158     | 157     | 157   | 144   | 144    | 145    |
| <b>Míry variability</b> |         |         |         |       |       |        |        |
| Směrodatná odchylka     | 0,7     | 13,8    | 16,0    | 14,1  | 9,9   | 9,0    | 9,0    |
| Variační koeficient (%) | 0,3     | 8,8     | 10,3    | 8,9   | 6,9   | 6,3    | 6,2    |

Tak jako v předchozí testované skupině, také ve skupině testování pro region 3 došlo ke zvýšení hodnot maxima a minima ve srovnání s druhou sérií měření. Většinou se jasové hodnoty konkrétního času pohybují v obdobných číslech, jedinou vybočující skupinou je skupina snímku za 48 hodin, u níž je značně nižší hodnota minima a díky poměrně vysoké hodnotě maxima má vyšší rozptyl dat než ostatní sledované skupiny, což potvrzují hodnoty směrodatné odchylky i variačního koeficientu, které se ale obecně pohybují velmi nízko.

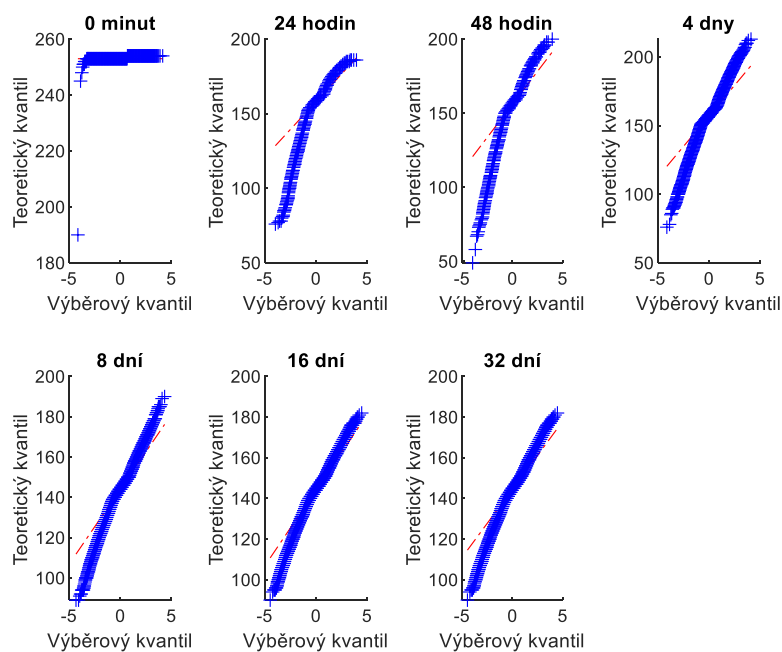
### 11.12.1 Dvouvýběrové charakteristiky pro region 3

Na Obrázku 80 jsou uvedeny boxploty pro region 3 ve všech zkoumaných časech. Jsou zde patrné odlehle pozorování, nejvíce jich je u snímku za 24 hodin.




Obrázek 80: Boxploty pro region 3 – 0 minut, 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin

Obrázek 81 demonstruje QQ grafy, dle nichž není pravděpodobné, že se bude jednat o normální rozložení sledovaných dat.



Obrázek 81: QQ grafy pro region 3 v první sérii měření

Histogramy na Obrázku 82 pravděpodobně potvrdí, že se nejedná o data z normální distribuce.



Obrázek 82: Histogramy pro region 3 v první sérii měření

Pro ověření předpokladů z QQ grafů a následně histogramů, že se nejedná o normální distribuci dat byl použit Kolmogorův-Smirnov test a na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 3 pocházejí z normálního rozložení.

$H_A$ :  $\neg H_0$

Tabulka 38: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 3

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 48 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 4 dny    | $<<0,001$ | zamítnutí $H_0$ |
| 8 dní    | $<<0,001$ | zamítnutí $H_0$ |
| 16 dní   | $<<0,001$ | zamítnutí $H_0$ |
| 32 dní   | $<<0,001$ | zamítnutí $H_0$ |

Na hladině významnosti 5 % zamítám u všech testovaných skupin nulovou hypotézu, data nepochází z normálního rozložení. Výsledky jsou uvedeny v Tabulka 38.

Z důvodu zamítnuté normality je pro další testování využít Levenův test a na hladině významnosti 5 % je definována nulová a alternativní hypotéza ve znění:

$H_0: \sigma_{1...7}^2 = \sigma_{1...7}^2$

$H_A: \neg H_0$

Na hladině významnosti 5 % nezamítám shodu rozptylů u jediné skupiny 16 a 32. U zbylých testovaných skupin lze s 95% spolehlivostí říct, že nemají shodný rozptyl.

Pro ověření shody středních hodnot, resp. mediánů je pro data, nepocházející z normální distribuce, použit dvouvýběrový Mannův-Whitneyův test a jsou definovány hypotézy:

$$H_0: x_{0,5_{1...7}} = x_{0,5_{1...7}}$$

$$H_A: \neq H_0$$

Na hladině významnosti 5 % zamítám předpoklad shody mediánů u všech testovaných skupin. Výsledky Levenova a Mannova-Whitneyova testů jsou uvedeny v Tabulka 39.

Tabulka 39: Dvouvýběrové charakteristiky pro region 3 ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí        | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí      |
|---------|---------------------------|-------------------|--|-----------------|
| 0 a 24  | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 0 a 48  | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 0 a 4   | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 0 a 8   | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 0 a 16  | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 0 a 32  | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 24 a 48 | $9,13 \cdot 10^{-34}$     | zamítnutí $H_0$   | $1,60 \cdot 10^{-32}$                  | zamítnutí $H_0$ |
| 24 a 4  | $3,09 \cdot 10^{-6}$      | zamítnutí $H_0$   | $1,26 \cdot 10^{-8}$                   | zamítnutí $H_0$ |
| 24 a 8  | $1,84 \cdot 10^{-235}$    | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 24 a 16 | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 24 a 32 | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 48 a 4  | $1,42 \cdot 10^{-22}$     | zamítnutí $H_0$   | $7,36 \cdot 10^{-16}$                  | zamítnutí $H_0$ |
| 48 a 8  | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 48 a 16 | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 48 a 32 | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 4 a 8   | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 4 a 16  | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 4 a 32  | <<0,001                   | zamítnutí $H_0$   | <<0,001                                | zamítnutí $H_0$ |
| 8 a 16  | $5,35 \cdot 10^{-81}$     | zamítnutí $H_0$   | $3,41 \cdot 10^{-16}$                  | zamítnutí $H_0$ |
| 8 a 32  | $1,23 \cdot 10^{-81}$     | zamítnutí $H_0$   | $5,37 \cdot 10^{-28}$                  | zamítnutí $H_0$ |
| 16 a 32 | 0,93                      | nezamítnutí $H_0$ | $4,88 \cdot 10^{-4}$                   | zamítnutí $H_0$ |

### 11.12.2 Vícevýběrové charakteristiky pro region 3

Předchozím testování byla zamítnuta normalita, proto je pro multitestování opět použit Levenův test a na hladině významnosti 5 % jsou definovány hypotézy:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_7^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, jasové složky nemají shodný rozptyl (p-hodnota = <<0,001).

Ověření shody měrných poloh je realizováno (vzhledem k zamítnuté normalitě) prostřednictvím Kruskal-Wallisova testu a na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_7}$$

$$H_A: \neg H_0$$

S 95% spolehlivostí lze říci, že u alespoň dvou testovaných skupin si nejsou mediány rovny. Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní. Výsledky demonstruje Tabulka 40.

Tabulka 40: Kruskal-Wallisův test pro region 3

|                   | Součet čtverců       | Stupně volnosti | Průměr čtverců       | Chí-kvadrát | P-hodnota |
|-------------------|----------------------|-----------------|----------------------|-------------|-----------|
| Skupinový faktor  | $1,96 \cdot 10^{15}$ | 6               | $3,28 \cdot 10^{14}$ | 129582,21   | <<0,001   |
| Reziduální faktor | $4,51 \cdot 10^{15}$ | 426838          | $1,06 \cdot 10^{10}$ | -           | -         |
| Celkem            | $6,47 \cdot 10^{15}$ | 426844          | -                    | -           | -         |

Pro bližší specifikaci, o které skupiny se jedná je provedena post-hoc analýza metodou Dunnové, jejíž výsledky jsou uvedeny v příloze Tab. 8. Díky post-hoc analýze je patrné, že u všech šesti zkoumaných skupin se mediány liší (p-hodnoty = <<0,001).

### 11.13 Statistická analýza první série měření pro region 4

Deskriptivní statistika regionu 4 v první sérii měření je uvedena v Tabulce 41. Stejně jako u druhé série měření neobsahuje region 4 žádnou jasovou složku pro snímek exponovaný za 0 minut.


Tabulka 41: Deskriptivní statistické údaje pro region 4 v první sérii měření

|                         | 0 minut | 24 hod. | 48 hod. | 4 dny | 8 dní | 16 dní | 32 dní |
|-------------------------|---------|---------|---------|-------|-------|--------|--------|
| Počet jasových složek   | 0       | 20764   | 13266   | 26655 | 73024 | 149013 | 142978 |
| <b>Míry polohy</b>      |         |         |         |       |       |        |        |
| Maximum                 | -       | 186     | 200     | 220   | 190   | 186    | 186    |
| Horní kvartil           | -       | 166     | 166     | 168   | 154   | 155    | 155    |
| Minimum                 | -       | 56      | 56      | 63    | 87    | 93     | 94     |
| Dolní kvartil           | -       | 153     | 151     | 153   | 143   | 144    | 145    |
| Průměr                  | -       | 158,2   | 157,0   | 159,8 | 149,8 | 148,8  | 149,3  |
| Medián                  | -       | 162     | 160     | 162   | 149   | 150    | 150    |
| <b>Míry variability</b> |         |         |         |       |       |        |        |
| Směrodatná odchylka     | -       | 13,8    | 15,6    | 14,2  | 9,8   | 8,9    | 8,8    |
| Variační koeficient (%) | -       | 8,7     | 9,0     | 8,9   | 6,9   | 5,9    | 5,9    |

Minimum pro region 4 vykazuje stejnou vlastnost u obou sérií měření, a to lineární nárůst. Obecně se však snímky pohybují v obdobných číslech. Opět jsou velmi nízké hodnoty pro míry variability, což značí málo rozptýlený soubor.

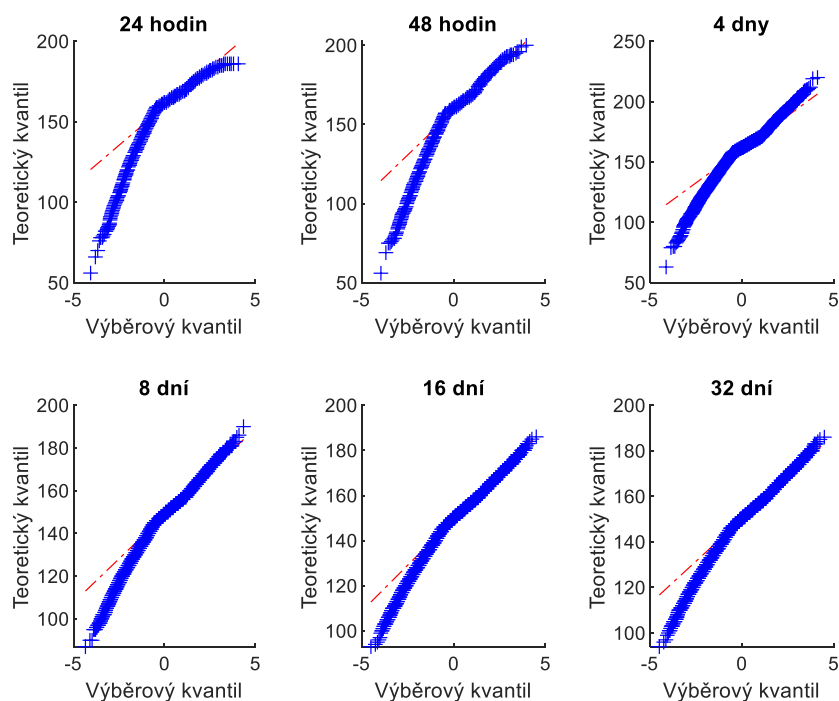
#### 11.13.1 Dvouvýběrové charakteristiky pro region 4

Pro zhodnocení povahy dat, jsou vyneseny boxploty, QQ grafy a histogramy a je ověřena normalita vizuálně a následně matematicky. Na Obrázku 83 jsou uvedeny příslušné boxploty, rovněž obsahují značný počet odlehlých pozorování.



Obrázek 83: Boxploty pro region 4 – 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin


Ačkoli by se mohlo zdát, že jsou data svou distribucí na QQ grafech (Obrázek 84) rovnoběžná s přímkou, jejich krajní hodnoty se od přímky značně odchyľují, proto také pravděpodobně nepůjde o normální rozložení dat.



Obrázek 84: QQ grafy pro region 4 v první sérii měření



Na Obrázku 85 jsou uvedeny histogramy distribucí pro region 4, na nichž je zřejmé, že data nebudou pravděpodobně pocházet z normálního rozložení, jelikož obsahují viditelné výchylky od pomyslné Gaussovské křivky.



Obrázek 85: Histogramy pro region 4 v první sérii měření

Kolmogorův-Smirnov test normality byl použit pro všechny časy a distribuce regionu 4 jako jednovýběrový test. Na hladině významnosti 5 % jsou definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 4 pocházejí z normálního rozdělení.

$H_A: \neg H_0$

Tabulka 42: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 4

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 48 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 4 dny    | $<<0,001$ | zamítnutí $H_0$ |
| 8 dní    | $<<0,001$ | zamítnutí $H_0$ |
| 16 dní   | $<<0,001$ | zamítnutí $H_0$ |
| 32 dní   | $<<0,001$ | zamítnutí $H_0$ |

Na základě testu normality zamítám na hladině významnosti 5 % nulovou hypotézu u všech testovaných skupin, data nepocházejí z rozdělení (p-hodnota  $<<0,001$ ). Výsledky uvádí Tabulka 42.

Pro Levenův test ověření homoskedasticity je na hladině významnosti 5 % definována nulová a alternativní hypotéza:

$$H_0: \sigma_{1...6}^2 = \sigma_{1...6}^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, všechny testované skupiny jsou heteroskedasticitní.

Pro ověření shody mediánů je použit je vzhledem k nepotvrzené normalitě dat použit Mannův-Whitneyův test a jsou definovány hypotézy:

$$H_0: x_{0,5_{1...6}} = x_{0,5_{1...6}}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám u všech dvouvýběrových testů nulovou hypotézu, mediány si v žádné skupině nejsou rovny. Všechny výsledky testů (Levenův i Mannův-Whitneyův) uvádí Tabulka 43.

Tabulka 43: Dvouvýběrové charakteristiky pro region 4 ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí      | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí      |
|---------|---------------------------|-----------------|--|-----------------|
| 24 a 48 | $4,03 \cdot 10^{-32}$     | zamítnutí $H_0$ | $1,51 \cdot 10^{-22}$                  | zamítnutí $H_0$ |
| 24 a 4  | $<<0,001$                 | zamítnutí $H_0$ | $6,82 \cdot 10^{-15}$                  | zamítnutí $H_0$ |
| 24 a 8  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 16 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 24 a 32 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 4  | $1,54 \cdot 10^{-22}$     | zamítnutí $H_0$ | $2,78 \cdot 10^{-58}$                  | zamítnutí $H_0$ |
| 48 a 8  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 16 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 48 a 32 | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 8   | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 16  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 4 a 32  | $<<0,001$                 | zamítnutí $H_0$ | $<<0,001$                              | zamítnutí $H_0$ |
| 8 a 16  | $1,71 \cdot 10^{-67}$     | zamítnutí $H_0$ | $1,55 \cdot 10^{-136}$                 | zamítnutí $H_0$ |
| 8 a 32  | $2,14 \cdot 10^{-121}$    | zamítnutí $H_0$ | $9,75 \cdot 10^{-273}$                 | zamítnutí $H_0$ |
| 16 a 32 | $1,55 \cdot 10^{-14}$     | zamítnutí $H_0$ | $1,06 \cdot 10^{-38}$                  | zamítnutí $H_0$ |

### 11.13.2 Vícevýběrové charakteristiky pro region 4

U dvouvýběrových testů byla na základě Kolmogorova-Smirnova testu zamítnuta normalita, tudíž je pro ověření shody rozptylů využit Levenův test a na hladině významnosti 5 % jsou definovány hypotézy: Na hladině významnosti 5 % je pro Levenův test definována nulová a alternativní hypotéza:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_6^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám předpoklad o homoskedasticitě, jasové složky nemají shodný rozptyl. (p-hodnota = <<0,001).

Pro další analýzu je použit Kruskal-Wallisův test pro heteroskedasticitní data a jsou definovány hypotézy na hladině významnosti 5 %:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_6}$$

$$H_A: \neg H_0$$

S 95% spolehlivostí lze tvrdit, že alespoň u dvou testovaných skupin si mediány nejsou rovny, tudíž na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní. Výsledky dokládá Tabulka 44.

Tabulka 44: Kruskal-Wallisův test pro region 4

|                   | Součet čtverců       | Stupně volnosti | Průměr čtverců       | Chí-kvadrát | P-hodnota |
|-------------------|----------------------|-----------------|----------------------|-------------|-----------|
| Skupinový faktor  | $7,00 \cdot 10^{14}$ | 5               | $1,40 \cdot 10^{14}$ | 46406,92    | <<0,001   |
| Reziduální faktor | $5,72 \cdot 10^{15}$ | 425694          | $1,34 \cdot 10^{10}$ | -           | -         |
| Celkem            | $6,42 \cdot 10^{15}$ | 425699          | -                    | -           | -         |

Z důvodu zamítnutí nulové hypotézy o shodě mediánu je provedena post-hoc analýza metodou Dunnové, jejíž výsledky jsou uvedeny v příloze Tab. 9. Mediány si u žádné testované skupiny nejsou rovny (p-hodnoty = <<0,001).

## 11.14 Statistická analýza první série měření pro region 5

Deskriptivní statistiku pro region 5 znázorňuje Tabulka 45.


Tabulka 45: Deskriptivní statistické údaje pro region 5 v první sérii měření

|                         | 0 minut | 24 hod. | 48 hod. | 4 dny  | 8 dní  | 16 dní | 32 dní |
|-------------------------|---------|---------|---------|--------|--------|--------|--------|
| Počet jasových složek   | 823547  | 423368  | 385646  | 293409 | 202426 | 154347 | 152546 |
| <b>Míry polohy</b>      |         |         |         |        |        |        |        |
| Maximum                 | 254     | 187     | 202     | 239    | 239    | 200    | 246    |
| Horní kvartil           | 254     | 176     | 179     | 180    | 164    | 164    | 164    |
| Minimum                 | 190     | 51      | 42      | 41     | 86     | 97     | 97     |
| Dolní kvartil           | 254     | 159     | 157     | 158    | 148    | 151    | 151    |
| Průměr                  | 253,8   | 165,5   | 166,2   | 168,0  | 155,6  | 157,1  | 157,4  |
| Medián                  | 254     | 169     | 169     | 169    | 157    | 158    | 158    |
| <b>Míry variability</b> |         |         |         |        |        |        |        |
| Směrodatná odchylka     | 2,0     | 14,8    | 18,1    | 17,6   | 12,2   | 10,6   | 10,8   |
| Variační koeficient (%) | 0,8     | 8,9     | 10,9    | 10,5   | 7,8    | 6,7    | 6,9    |

Stejně jako při měření ve druhé sérii zde není patrná žádná linearita, při testování se však pracuje jen s velmi málo rozptýleným souborem.

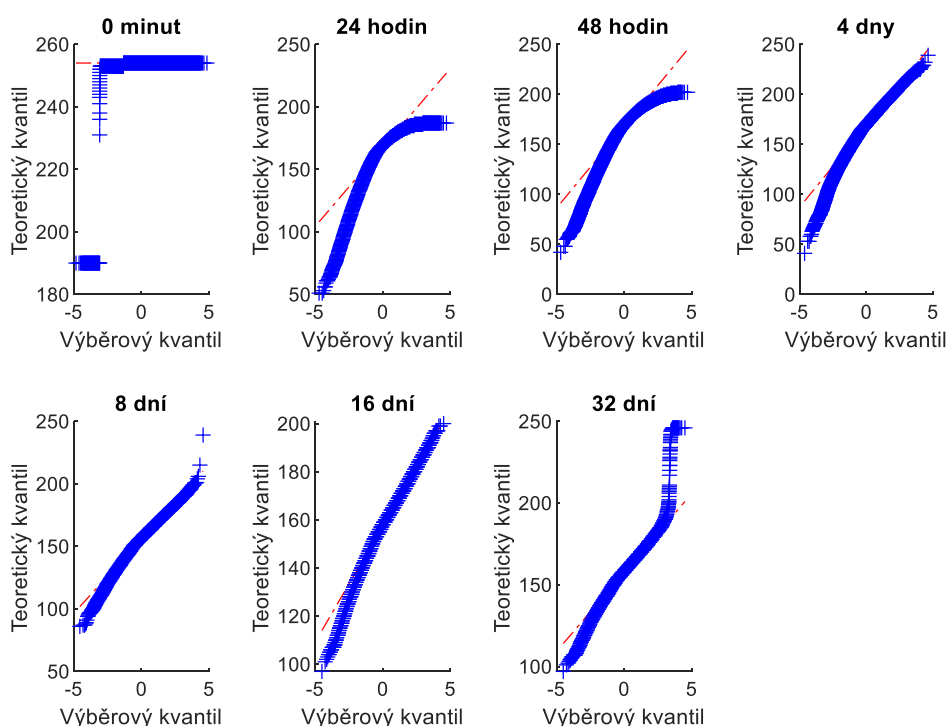
### 11.14.1 Dvouvýběrové charakteristiky pro region 5

Ověření normality je prováděno obdobně jako u předchozích skupin a to histogramy, QQ grafy a následně Kolmogorovým-Smirnovým testem normality dat. Na Obrázku 86 jsou znázorněny boxploty pro region 5 v první sérii měření, tak jako u naprosto všech zkoumaných skupin ve všech časech jsou zde přítomna odlehlá pozorování.




Obrázek 86: Boxploty pro region 5 – 0 minut, 4, 8, 16 dní, 24 hodin, 32 dní a 48 hodin

QQ grafy - Obrázek 87, pravděpodobně nebudou pocházet z normálního rozložení, neboť se ve většině případů odchylují od přímky, která data prokládá. Na Obrázku 88 jsou následně uvedeny histogramy pro distribuci z 5 regionu.



Obrázek 87: QQ grafy pro region 5 v první sérii měření



Obrázek 88: Histogramy pro region 5 v první sérii měření

Pro ověření normality byl použit Kolmogorův-Smirnovův test a na hladině významnosti 5 % byly definovány hypotézy:

$H_0$ : Jasové hodnoty v regionu 5 pocházejí z normálního rozdělení.

$H_A: \neg H_0$

Tabulka 46: Ověření normality Kolmogorovým-Smirnovým testem u dat z regionu 5

| Čas      | p-hodnota | Rozhodnutí      |
|----------|-----------|-----------------|
| 0 minut  | $<<0,001$ | zamítnutí $H_0$ |
| 24 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 48 hodin | $<<0,001$ | zamítnutí $H_0$ |
| 4 dny    | $<<0,001$ | zamítnutí $H_0$ |
| 8 dní    | $<<0,001$ | zamítnutí $H_0$ |
| 16 dní   | $<<0,001$ | zamítnutí $H_0$ |
| 32 dní   | $<<0,001$ | zamítnutí $H_0$ |

Na základě Kolmogorova-Smirnova testu je na hladině významnosti 5 % zamítnuta normalita u všech zkoumaných dat (p-hodnoty jsou  $<<0,001$ ). Výsledky jsou uvedeny v Tabulce 46.

Pro ověření homoskedasticity byl použit Levenův test a byla definována základní nulová a alternativní hypotéza:

$H_0: \sigma_{1...7}^2 = \sigma_{1...7}^2$

$H_A: \neg H_0$

Na hladině významnosti 5 % zamítám nulovou hypotézu ve prospěch alternativní hypotézy, všechna rozdělení nemají stejný rozptyl, tedy jsou heteroskedasticitní. Tento rozdíl lze označit za statisticky významný.

Jelikož se jedná o data bez normálního rozdělení je pro zjištění shody středních hodnot, respektive mediánů použit Mannův-Whitneyův test a jsou definovány hypotézy:

$$H_0: x_{0,5_{1...7}} = x_{0,5_{1...7}}$$

$$H_A: \neq H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, mediány jasových hodnot si nejsou rovny. Veškeré hodnoty specifikuje Tabulka 47.

Tabulka 47: Dvouvýběrové charakteristiky pro region 5 ve všech kombinacích

| Regiony | Levenův test<br>p-hodnota | Rozhodnutí      | Mannův-<br>Whitneyův test<br>p-hodnota | Rozhodnutí      |
|---------|---------------------------|-----------------|--|-----------------|
| 0 a 24  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 48  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 4   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 8   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 16  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 0 a 32  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 24 a 48 | $1,50 \cdot 10^{-320}$    | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 24 a 4  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 24 a 8  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 24 a 16 | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 24 a 32 | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 48 a 4  | $2,10 \cdot 10^{-43}$     | zamítnutí $H_0$ | $9,21 \cdot 10^{-128}$                 | zamítnutí $H_0$ |
| 48 a 8  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 48 a 16 | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 48 a 32 | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 4 a 8   | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 4 a 16  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 4 a 32  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 8 a 16  | <<0,001                   | zamítnutí $H_0$ | $3,53 \cdot 10^{-224}$                 | zamítnutí $H_0$ |
| 8 a 32  | <<0,001                   | zamítnutí $H_0$ | <<0,001                                | zamítnutí $H_0$ |
| 16 a 32 | $9,70 \cdot 10^{-4}$      | zamítnutí $H_0$ | $1,62 \cdot 10^{-17}$                  | zamítnutí $H_0$ |

### 11.14.2 Vícevýběrové charakteristiky pro region 5

Z důvodu zamítnuté normality viz. Tabulka 46 je pro vícevýběrové charakteristiky použit vícevýběrový Levenův test pro ověření shody rozptylů a na hladině 5 % jsou definovány hypotézy:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_7^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám předpoklad o shodě rozptylů, jasové složky nemají shodný rozptyl. (p-hodnota = <<0,001).

Vzhledem k zamítnuté normalitě je potřeba pracovat s mediány jasových hodnot. Pro ověření shody měrných poloh byl využit Kruskal-Wallisův test a na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_7}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % zamítám nulovou hypotézu, alespoň u jedné skupiny se mediány nerovnají. Výsledky demonstruje Tabulka 48.

Tabulka 48: Kruskal-Wallisův test pro region 5

|                   | Součet čtverců       | Stupně volnosti | Průměr čtverců       | Chí-kvadrát       | P-hodnota |
|-------------------|----------------------|-----------------|----------------------|-------------------|-----------|
| Skupinový faktor  | $8,53 \cdot 10^{17}$ | 6               | $1,42 \cdot 10^{17}$ | $1,78 \cdot 10^6$ | <<0,001   |
| Reziduální faktor | $3,16 \cdot 10^{17}$ | 2435282         | $1,29 \cdot 10^{11}$ | -                 | -         |
| Celkem            | $1,17 \cdot 10^{15}$ | 2435288         | -                    | -                 | -         |

Pro další analýzu je provedena post-hoc analýza metodou Dunnové. Díky post-hoc analýze je patrné, že u všech šesti zkoumaných skupin se mediány liší (p-hodnoty = <<0,001). Výsledky jsou doloženy v příloze Tab. 10.

## 11.15 Shrnutí statistické analýzy

U všech testovaných skupin došlo k zamítnutí normality, následně byla u většiny dvouvýběrových testů, test homoskedasticity a shody mediánů, zamítnuta nulová hypotéza. V některých případech hypotézy zamítnuty nebyly, jednalo se o skupiny z první i druhé série měření. Jejich výskyt byl však velmi ojedinělý a neobsahoval opakující se vlastnosti. U vícevýběrových testů byla ve všech případech všech testovaných skupin zamítnuta homoskedasticita i shoda mediánů. Lze tvrdit, že data nedisponují shodnými vlastnostmi a dynamicky dochází v čase k jejich změnám.



## 12 Návrh predikčního modelu pro modelování závislosti míry poškození paměťové fólie na dozimetrickém měření

Návrh predikčního modelu je uskutečněn pomocí dvou forem fitování, to jak lineárního, tak i nelineárního. Je zkoumáno, která z těchto dvou metod bude lépe kopírovat průběh dat.

Samotné fitování je metodou, která ve svém principu vytváří přímku, nebo, v případě nelineárního, křivku, nejlépe kopírující uvedená data. Existuje řada regresních modelů, využívajících různé matematické funkce, mezi nejužívanější se řadí:

1. Lineární regrese,
2. Polynomiální regrese,
3. Binomická regrese,
4. Generalizovaný lineární model,
5. Exponenciální regrese,
6. Fourierova regrese apod.

Pro práci s daty byl využit toolbox *cftool* v prostředí Matlab R2016a. *Cftool* neboli Curve Fitting toolbox poskytuje flexibilní rozhraní, kde se data dají jednoduše proložit prostřednictvím křivek/přímek a následně zobrazovat grafy. Tento toolbox umožňuje vytvářet, vykreslovat a srovnávat více sad dat, využívat lineární či nelineární regrese, interpolace, interpolace a vlastní rovnice apod. Pro práci byly vybrány dva modely, a to jeden lineární a druhý nelineární. [44]

### 12.1 Lineární predikční model

Jako lineární model je vybrán model polynomiální regrese. Pracuje na principu modelování vztahu polynomu  $n$ -tého stupně v  $x$  z nezávislé proměnné  $x$  a závislé proměnné  $y$ . Ačkoli model odpovídá nelineárnímu vztahu mezi hodnotou  $x$  a podmíněným průměrem  $y$ , označeným jako  $E(y|x)$ , považuje se jako problém statistického odhadu za lineární. Je to z toho důvodu, že funkce  $E(y|x)$  je lineární v neznámých parametrech, které jsou odhadem z dat, a právě proto je polynomiální regrese považována za případ vícenásobné lineární regrese. Do práce se její výstupy jeví jako nejvhodnější. Obecný předpis (12.1) je následující:

$$y = \sum_{i=1}^{n+1} p_i x^{n+1-i}, \quad (12.1)$$


kde  $n+1$  je řád polynomu a udává, počet koeficientů, které mají být fitovány,  
 $n$  je stupeň polynomu ( $1 \leq n \leq 9$ ) dává, nejvyšší sílu predikční proměnné. [45][46]

Pro použití v práci je definována vztahem (12.2):

$$N = a \cdot D + b, \quad (12.2)$$

kde  $N$  je počet vzorků (osa  $Y$ ),  
 $D$  je dávka,  
 $a$  je hodnota sklonu čáry,  
 $b$  je hodnota průniku.

Obrázek 89 demonstruje lineární predikční model pro závislost počtu vzorků v regionu 5 na rostoucí dávce u druhé série měření, kde je patrný pokles přímky. Fakt, že dochází k poklesu počtu pixelů v regionu 5 je dán předpokladem, že s rostoucí délkou expozice se snižuje počet pixelů, které demonstrují oblasti bez působení přírodní radiace. Pokud bychom prováděli expozici po delší dobu, docházelo by stále k poklesu počtu pixelů až do doby, než by zůstala stopa na snímku pouze po přiloženém olověném plátku.



Obrázek 89: Polynomiální predikční model pro počet vzorků v regionu 5 v závislosti na dávce ve druhé sérii měření


Lineární predikční model na Obrázku 89 definují pro počátek (12.3), střed (12.4) a konec (12.5) přímky následující rovnice:

$$N = (-8646 \cdot D) + 1,37 \cdot 10^5, \quad (12.3)$$

$$N = (-3465 \cdot D) + 4,69 \cdot 10^5 \quad (12.4)$$

$$N = 1717 \cdot D + 8,00 \cdot 10^5. \quad (12.5)$$

Lineární predikční model pro klesající hodnoty mediánů ve druhé sérii měření je zobrazen na Obrázku 90.



Obrázek 90: Polynomiální predikční model pro mediány všech regionů v závislosti na dávce ve druhé sérii měření


Opět je zde patrný pokles hodnot mediánů a z toho plynoucí lineární model. Pokles hodnot však není u regionů 1, 2, 3, 4 i 5 od sebe výrazně odlišný, to stejné platí i u predikčního modelu pro region 1 (Obrázek 91). Strmost přímky není tak velká jako u predikčního modelu pro počet pixelů (Obrázek 89). Z dostupných parametrů jsou definovány rovnice pro počátek (12.6), střed (12.7) a konec přímky (12.8):

$$N = (-2,21 \cdot D) + 38, \quad (12.6)$$

$$N = (-0,58 \cdot D) + 141,90 \quad (12.7)$$

$$N = 1,04 \cdot D + 245,90. \quad (12.8)$$

Jak již bylo zmíněno, obdobná situace je viditelná i u predikčního modelu pro mediány z regionu 1 u druhé série měření (Obrázek 91). Dochází k poklesu hodnot, a tudíž je i přímka lineárně klesající.



Obrázek 91: Polynomiální predikční model pro mediány v regionu 1 v závislosti na dávce ve druhé sérii měření

Lze říct, že i přes nelineární růst počtu hodnot, dochází k lineárnímu poklesu mediánu. Tento jev může být přisouzen tomu, že výkyvy jasových hodnot v regionu 1 se snižují a s rostoucím časem


expozice. Jelikož region 1 je společně se regionem 5 (reprezentujícím oblast bez působení přírodní radiace) značně dominantním a následně dochází k obecnému zvyšování hodnot u regionu 2, 3 i 4 a tudíž i jejich větší výskyt ve výsledném segmentovaném obraze. Rovnice, popisující počátek (12.9), střed (12.10) a konec (12.11) přímky jsou definovány následovně:

$$N = (-2,28 \cdot D) + 29,98, \quad (12.9)$$

$$N = (-0,60 \cdot D) + 137,80, \quad (12.10)$$

$$N = 1,09 \cdot D + 245,60. \quad (12.11)$$

První série měření obsahuje trend v počtu jasových složek také pro region 2. Je možné, že i ve druhé sérii by tento trend bylo možno naleznout, avšak změna jasu a kontrastu tento trend nepotvrdila. Na Obrázku 92 můžeme pozorovat lineárně rostoucí predikční přímku, reprezentující vrůst počtu jasových složek v regionu 2 v první sérii měření v závislosti na rostoucí dávce.



Obrázek 92: Polynomiální predikční model pro počet vzorků v regionu 2 v závislosti na dávce v první sérii měření


Odpovídající rovnice pro počátek (12.12), střed (12.13) a konec (12.14) jsou definovány:

$$N = 323,80 \cdot D - 8290, \quad (12.12)$$

$$N = 678,4 \cdot D + 1,27 \cdot 10^4, \quad (12.13)$$

$$N = 1033 \cdot D + 3,38 \cdot 10^4. \quad (12.14)$$

Je zajímavé, že první i druhá série měření se shodují v klesající tendenci v regionu 5. Zatímco ve druhé sérii měření je díky pozmeněným vstupním parametrům počátek křivky posunut níž, tak sklon křivky ve středové hodnotě je u obou predikčních modelů takřka stejný. Lze tedy u predikčního modelu regionu 5 v první sérii měření (Obrázek 93), tak jako u lineárně-predikčního modelu pro druhou sérii měření, předpokládat úbytek počtu pixelů v regionu 5 až do doby, dokud se pixely z regionu 5 budou vyskytovat i mimo oblast uložení olověného plátu.



Obrázek 93: Polynomiální predikční model pro počet vzorků v regionu 5 v závislosti na dávce v první sérii měření


Lineární predikční model na Obrázku 93 definují pro počátek (12.15), střed (12.16) a konec (12.17) přímky následující rovnice:

$$N = (-7209 \cdot D) + 2,11 \cdot 10^5, \quad (12.15)$$

$$N = (-3006 \cdot D) + 4,59 \cdot 10^5, \quad (12.16)$$

$$N = 1196 \cdot D + 7,09 \cdot 10^5. \quad (12.17)$$

Ačkoliv v počtu pixelů nebyla lineární složka nalezena v mediánech pro všechny regiony ano. Tento případ je opět stejný u prvního i druhého měření s rozdílnými vstupními parametry. Nicméně, v první sérii měření je přímka položena výrazně dále než ve druhé sérii a je také strmější. Grafická prezentace závislosti mediánů pro všechny regiony na dávce je demonstrována na Obrázku 94.



Obrázek 94: Polynomiální predikční model pro mediány pro všechny regiony v závislosti na dávce v první sérii měření


Rovnice, popisující počátek (12.18), střed (12.19) a konec (12.20) přímky jsou definovány následovně:

$$N = (-1,17 \cdot D) + 132,80, \quad (12.18)$$

$$N = (-0,37 \cdot D) + 180,4, \quad (12.19)$$

$$N = 0,43 \cdot D + 228. \quad (12.20)$$

Predikční model je vytvořen také pro mediány v závislosti na rostoucí dávce v regionu 1 pro první sérii měření. Rovněž se jedná o model obdobný druhé sérii měření. Je proto zajímavé opakovaně pozorovat parametry, které jsou lineární u první i druhé série měření, které nejsou na sobě nijak závislé. Přímka z první série Obrázek 95 má strmější průběh než u druhé série a zároveň je i značně kratší.



Obrázek 95: Polynomiální predikční model pro mediány v regionu 1 v závislosti na dávce v první sérii měření

Polynomiální predikční model na Obrázku 95 definují pro počátek (12.21), střed (12.22) a konec (12.23) přímky následující rovnice:

$$N = (-1,27 \cdot D) + 123,1, \quad (12.21)$$

$$N = (-0,39 \cdot D) + 174,5, \quad (12.22)$$

$$N = 0,47 \cdot D + 225,8. \quad (12.23)$$

## 12.2 Nelineární predikční model

Exponenciální regrese je jednou z metod spadajících do nelineární predikce. Jedná se o proces nalezení rovnice exponenciální funkce, která nejlépe odpovídá souboru dat. Používá se především pro modelování situací, kde dochází k pomalému růstu a následně zrychluje, nebo naopak. Matlab toolbox nabízí jedno a dvoudobý exponenciální model, který je definován jako:

$$y = ae^{bx} ; y = ae^{bx} + ce^{dx} , \quad (12.24)$$


kde  $y$  jsou hodnoty osy  $y$   
 $x$  jsou hodnoty osy  $x$ ,  
 $a$  je hodnota sklonu čáry,  
 $b$  je hodnota průniku. [47][48]

Pro použití v práci je definována vztahem:

$$N = a \cdot \exp(D \cdot b) , \quad (12.25)$$

kde  $N$  je počet vzorků (osa  $Y$ ),  
 $D$  je dávka,  
 $a$  je hodnota sklonu čáry,  
 $b$  je hodnota průniku.

Nelineární predikční modely jsou vytvořeny na stejném podkladu jako modely lineární, data jsou však proložena exponenciálou, která lépe kopíruje průběh dat. U nelineárního modelu pro region 5 ve druhé sérii měření (Obrázek 96) vidíme klesající exponenciální funkci, zdola omezenou hodnotou 0,02, při dalším měření by pravděpodobně docházelo k dalšímu poklesu vlivem snižování hodnot pro region 5, až do doby ustálení. Je patrné, že nelineární model lépe kopíruje pokles dat a pro reálné zhodnocení je praktičtější než model lineární, neboť je patrné, že body nejsou v přímce, nýbrž v exponenciální funkci.



Obrázek 96: Exponenciální predikční model pro počet vzorků v regionu 5 v závislosti na dávce ve druhé sérii měření


Rovnice, popisující počátek (12.26), střed (12.27) a konec (12.28) křivky jsou definovány:

$$N = 2,83 \cdot 10^5 \cdot \exp(D \cdot (-0,09)), \quad (12.26)$$

$$N = 6,25 \cdot 10^5 \cdot \exp(D \cdot (-0,04)), \quad (12.27)$$

$$N = 9,66 \cdot 10^5 \cdot \exp(D \cdot 0,02). \quad (12.28)$$

Exponenciální model pro mediány ve všech regionech Obrázek 97 je velmi podobný modelu lineárnímu, neboť exponenciála, prokládající body není tak strmá, jako například u modelu předchozího (Obrázek 96). Její strmost se patrná až při značném zmenšení osy.



Obrázek 97: Exponenciální predikční model pro mediány ve všech regionech v závislosti na dávce ve druhé sérii měření


Exponenciální predikční model na Obrázku 97 definují pro počátek (12.29), střed (12.30) a konec (12.31) křivky následující rovnice:

$$N = 39,75 \cdot \exp(D \cdot (-0,03)), \quad (12.29)$$

$$N = 153,70 \cdot \exp(D \cdot (-0,01)), \quad (12.30)$$

$$N = 267,70 \cdot \exp(D \cdot 0,01). \quad (12.31)$$

Pro závislost mediánu v regionu 1 na dávce (Obrázek 98) je situace obdobná jako u všech regionů v druhé sérii měření a křivky obsahují i téměř totožné parametry.



Obrázek 98: Exponenciální predikční model pro mediány v regionu 1 v závislosti na dávce ve druhé sérii měření




Nelineární predikční model na Obrázku 98 definují pro počátek (12.32), střed (12.33) a konec (12.34) křivky následující rovnice:

$$N = 31,81 \cdot \exp(D \cdot (-0,03)), \quad (12.32)$$

$$N = 151,40 \cdot \exp(D \cdot (-0,01)), \quad (12.33)$$

$$N = 271 \cdot \exp(D \cdot 0,02). \quad (12.34)$$

Predikčně-nelineární model pro počet vzorků v závislosti na rostoucí dávce je znázorněn na Obrázek 99. Je patrné, že exponenciální model není příliš vhodný pro tento typ dat. Lepší by bylo pravděpodobně použít proložení např. rostoucí logaritmickou funkcí.



Obrázek 99: Exponenciální predikční model pro počet vzorků v regionu 2 v závislosti na dávce v první sérii měření


Rovnice, popisující počátek (12.35), střed (12.36) a konec (12.37) křivky jsou definovány následovně:

$$N = (-887,10) \cdot \exp(D \cdot 0,001), \quad (12.35)$$

$$N = 2,32 \cdot 10^4 \cdot \exp(D \cdot 0,01), \quad (12.36)$$

$$N = 4,72 \cdot 10^4 \cdot \exp(D \cdot 0,02). \quad (12.37)$$

Typickou exponenciální křivku můžeme pozorovat na Obrázku 100 pro predikční model závislosti počtu vzorků pro region 5 v první sérii měření na rostoucí dávce. Data jsou křivkou velmi dobře proložena a opět se zde nachází úzká podobnost s predikčním modelem pro region 5 ve druhé sérii měření. Lze tedy na základě predikčních modelů (lineárních i nelineárních) tvrdit, že 5. region se lineárně mění s rostoucí dávkou a to tak, že klesá.



Obrázek 100: Exponenciální predikční model pro počet vzorků v regionu 5 v závislosti na dávce v první sérii měření


Exponenciální predikční model pro 5. region v první sérii měření definují pro počátek (12.38), střed (12.39) a konec (12.40) křivky následující rovnice:

$$N = 3,55 \cdot 10^5 \cdot \exp(D \cdot (-0,09)), \quad (12.38)$$

$$N = 6,25 \cdot 10^5 \cdot \exp(D \cdot (-0,04)), \quad (12.39)$$

$$N = 8,94 \cdot 10^5 \cdot \exp(D \cdot 0,01). \quad (12.40)$$

Model závislosti mediánu na rostoucí dávce pro všechny regiony v první sérii měření je znázorněn na Obrázku 101. Opět zde křivka vypadá spíše jako přímka a typický exponenciální tvar lze vidět až při značném zúžení osy. Ve srovnání nelineárního modelu pro mediány všech regionů ve druhé sérii měření jsou obdobné, nicméně model pro druhou sérii vykazuje vyšší strmost na sledovaném intervalu (0-140).



Obrázek 101: Exponenciální predikční model pro mediány ve všech regionech v závislosti na dávce v první sérii měření


Odpovídající rovnice pro počátek (12.41), střed (12.42) a konec (12.43) predikční křivky jsou definovány:

$$N = 133,50 \cdot \exp(D \cdot (-0,01)), \quad (12.41)$$

$$N = 182,50 \cdot \exp(D \cdot (-0,003)), \quad (12.42)$$

$$N = 231,50 \cdot \exp(D \cdot 0,003). \quad (12.43)$$

Na Obrázku 102 je nelineární predikční model pro závislost mediánů v 1. regionu na rostoucí dávce. Jsou zde patrné obdobné hodnoty a exponenciální funkce opět není příliš strmá, jedná se tedy o stejný problém jako u předešlých exponenciálních modelů, které vynášely závislost mediánů na rostoucí dávce.



Obrázek 102: Exponenciální predikční model pro mediány v regionu 1 v závislosti na dávce v první sérii měření

Nelineární predikční model na Obrázku 102 definují pro počátek (12.44), střed (12.45) a konec (12.46) křivky následující rovnice:

$$N = 123,90 \cdot \exp(D \cdot (-0,01)), \quad (12.44)$$

$$N = 177 \cdot \exp(D \cdot (-0,003)), \quad (12.45)$$

$$N = 230,10 \cdot \exp(D \cdot 0,003). \quad (12.46)$$

Predikční modely byly vytvořeny také pro zbývající regiony v závislosti dávky na počtu pixelů v obou sériích měření, i přes to, že u nich nelze identifikovat lineární změny, lze vytvořit lineární i nelineární modely, které jasně dokazují, že ve všech regionech dochází k jejich postupnému růstu, zatímco u regionu 5 k jeho poklesu u obou sledovaných měření. Predikční modely pro mediány jsou v nelineární verzi vizuálně velmi blízko lineární, neboť jsou hodnoty vyneseny ke konci křivky. Křivky rovněž velmi ovlivňují hodnoty mediánů za 0 minut, které jsou oproti ostatním velmi vysoké a je tedy otázkou, jak moc by došlo ke změně modelů bez této hodnoty. Jednotlivé predikční modely jsou uvedeny v příloze.

## Diskuze

Práce zpracovává opravdu široké téma, které by mohlo být i nadále rozvíjeno a analyzováno. Experiment akvizice obrazů by bylo možno navrhnout pro jiné vstupní parametry, než byly pro první a druhou sérii měření. Bylo by zajímavé sledovat rozdílný vliv přírodní radiace s měnící se nadmořskou výškou. Tyto rozdíly by však musely být dynamické, aby se to na výstupním obrazu projevilo. Rovněž by byl problém s vyvoláním, jelikož ne všude jsou podmínky k realizaci experimentu vhodné. Pro další experimenty by mohly být užity různé materiály jiných absorpčních koeficientů, které jsou v ovládací místnosti radiologických asistentů běžně přítomné.

Vstupní otázkou je zhodnocení obou sérií měření, neboť každá byla pořízena s rozdílnými vstupními parametry. Ačkoli by se druhá série mohla zdát pro vizuální posouzení lepší, neboť obrazová informace je při změně kontrastu a jasů zřetelněji viditelná, je obrazová segmentace u obou sérií téměř totožná. Také je otázkou, zdali změna parametrů nepotlačila trend v počtu pixelů u regionu 2, jelikož u měření v první sérii byl trend nalezen a ve druhé nikoli. Také v ostatních regionech (např. region 4 ve druhé sérii měření) by s rostoucím expozičním časem mohly být nalezeny opakující se složky, nejpatrnější počet výchylek byl totiž právě pro snímky vyvolané v krátkém časovém úseku. Je proto možné, že by se efektivita měření zvýšila, pokud by byly snímky vyvolány ve větším časovém rozestupu. Rozhodně by bylo zajímavé provést další série měření.

Statistická analýza provedená prostřednictvím dvouvýběrových a vícevýběrových testových analýz s sebou nesla ve většině případů obdobné výsledky. Mírně rozdílné výsledky však můžeme pozorovat při ověření shody mediánů. V některých případech dvouvýběrových testů, to konkrétně u regionu 2 (srovnávané skupiny za 2 a 3 týdny) a 4 (srovnávané skupiny za 24 hodin a 2 týdny) ve druhé sérii měření a u regionu 2 (srovnávané skupiny za 8 dnů a 16 dnů) v první sérii měření, došlo k potvrzení nulové hypotézy o shodě mediánů, naopak u vícevýběrových testů testovací statistika pomocí Kruskal-Wallisova testu zamítla tento předpoklad u všech skupin. Při bližší post-hoc analýze metodou Dunnové bylo zjištěno, že u všech testovaných skupin byla shoda mediánů zamítnuta a u žádných dvou skupin si mediány nebyly rovny. Je možné, že k těmto výsledkům došlo právě užitím rozdílné testovací statistiky a možná i tím, že u vícevýběrových testů se pracuje s velkým objemem dat najednou.

Predikční modely byly vytvořeny jak lineární, tak i nelineární. Už z charakteru dat bylo jasné, že lineární modely nebudou pro predikci úplně vhodné, nicméně na nich lze jasně vidět povaha dat a zdali se jedná o predikci klesající, či rostoucí. Exponenciální modely lépe kopírují charakter dat, avšak u rostoucích dat by pravděpodobně bylo vhodnější použití logaritmického modelu. Z predikčních modelů lze však jednoznačně zhodnotit, že by postupně docházelo k vyšší degradaci, jelikož region 5, reprezentující přírodní radiaci by byl přítomen pouze v oblasti umístění olověné gumy a ostatní regiony by byly přítomny ve zbývajících částech kazety.

Práce se ve výsledků jeví jako velmi obsáhlá, avšak pro vhodnou a dostatečnou analýzu bylo potřeba zpracovat velký objem dat a výstupů. Idea práce lze použít pro další řešitele obdobné problematiky, neboť na vliv ionizujícího záření se lze zaměřit v různých odvětvích jak medicíny, tak i průmyslu.

## Závěr

Práce se zaměřuje na studium degradace obrazů vlivem ionizujícího záření, také na samotné ionizující záření, radiometrickou měřicí techniku a obrazové zpracování. Vstupní data nejsou standartní, jelikož se jedná pouze o možný vliv přírodní radiace na skiagrafickou kazetu pro nepřímou digitalizaci, na níž byl umístěn olověný plátek jako prvek, umožňující absorpci ionizujícího záření. Byly provedeny expozice ve dvou sériích. Pro tuto práci byla provedena druhá série měření za 24 hodin, 1, 2, 3 a 4 týdny. První série měření byla k dispozici od studentky OSU. Sledovalo se, jak se od sebe jednotlivé série liší, zdali vykazují stejný nebo alespoň podobný trend a zdali změna kontrastu a jasu může ovlivnit výstupy.

Široké spektrum segmentačních metod poskytuje značné možnosti v oblasti zpracování obrazů. V práci je využito technik prahování, a to konkrétně metod OTSU a Fuzzy. V první části je testováno jak z hlediska vizuálního, tak i matematického posouzení těchto dvou metod vůči sobě. Matematickým testováním se došlo k závěru, že by metoda Fuzzy měla být pro segmentaci obrazu lepší, neboť lépe pracuje se šumem. Tento fakt bylo potřeba ověřit také vizuálně, a to výstupním segmentovaným obrazem. Vstupní obraz je v podstatě pouze šum, proto byl pro obě metody poměrně náročný ke zpracování. Metoda Fuzzy se však ověřila i v této oblasti a rozdělení do 5 regionů se jevilo jako neoptimálnějších. Po provedené segmentaci bylo možné odseparovat jasové složky a načít data zpracovávat statisticky vhodnou deskriptivní a explorační analýzou.

Pro testování normality dat je opět možné užití několika způsobů od vizuálních až po matematické. Ideálně se testování provádí oběma způsoby, neboť vizuální stránka dat může být někdy zkreslená a pozorovatel není schopen jednoznačně odhadnout charakter dat. V práci jsou použity obě metody, vizuální hodnocení je provedeno pomocí histogramů a QQ grafů, matematické pak Kolmogorovým-Smirnovým testem normality. Po zhodnocení normality, která byla na základě Kolmogorova-Smirnova testu na hladině 5 % u všech testovaných skupin zamítnuta je možné provádět dvouvýběrové i vícevýběrové testy. Pro dvouvýběrové charakteristiky je na hladině 5 % použit Levenův test pro ověření homoskedasticity a pro ověření shody mediánů je na hladině významnosti 5 % použit Mannův-Whitneyův test. U vícevýběrových testů je pro ověření shody rozptylů opět použit Levenův vícevýběrový test a pro ověření shody měrných poloh, resp. mediánů je užit Kruskal-Wallisův test (opět se u obou testů pracuje s hladinou významnosti 5 %). Ve velké většině případů došlo k zamítnutí nulových hypotéz, a tudíž lze dojít k závěru, že data nepocházejí z normálního rozložení, rovněž nejsou homoskedastické ani se jejich mediány nerovnají, tyto výsledky jsou shodné pro dvou i vícevýběrové testy a lze tedy soudit, že s rostoucí expozicí dochází ke změnám vlivem přírodní radiace a nejedná se např. o chemické vlivy, které by měly za následek odlišné chování a převládalo by potvrzení nulových hypotéz, namísto jejich zamítnutí jak je tomu v této práci.

V poslední části byly provedeny návrhy predikčních modelů pro regiony, vykazující trendy buď v počtu pixelů nebo změnách mediánu. Predikční modely posoudily data v závislosti na rostoucí dávce, která byla změřena dozimetrem. Je zajímavé, že se ve většině případů podařilo ze dvou nezávislých měření nalézt podobné trendy, a zhodnotit tak, že u regionu 5, reprezentujícího oblast bez působení přírodní radiace, došlo k výraznému poklesu jasových složek u obou měření. U první série měření je trend také v naopak rostoucím zastoupení regionu 2. Lepších výsledků je dosaženo nelineárními modely, a to především u hodnocení počtu pixelů v závislosti na čase. U mediánů je pokles velmi malý, a tudíž nelze jednoznačně posoudit, který typ modelu je pro jejich pokles výhodnější.

## Seznam použitých zdrojů

- [1] BROMOVÁ, Edita, Dušan VARGONČÍK a Michael SOVADINA. Jaderná energie a energetika. Simopt, 2013. ISBN 978-80-87851-01-2
- [2] ULLMANN, Vojtěch. Aplikace ionizujícího záření v radiologických oborech: skriptum. Ostrava: Ostravská univerzita, 2013. ISBN 978-80-7464-211-1
- [3] ŠVEC, Jiří. Radiační fyzika: skriptum. Ostrava: Ostravská univerzita v Ostravě, 2014. ISBN 978-80-7464-572-3
- [4] What Is Background Radiation? World Nuclear Association [online]. London, 2016-2020, 1 [cit. 2019-09-24]. Dostupné z: [http://www.worldnuclear.org/uploadedFiles/org/Features/Radiation/4\\_Background\\_Radiation%201%29.pdf](http://www.worldnuclear.org/uploadedFiles/org/Features/Radiation/4_Background_Radiation%201%29.pdf)
- [5] Přírodní radioaktivita a problematika radonu. Státní ústav radiační ochrany [online]. Praha: SÚRO, 2000 [cit. 2019-09-24]. Dostupné z: <https://www.suro.cz/cz/prirodnioz>
- [6] Ozáření z přírodních zdrojů záření. Státní úřad pro jadernou bezpečnost [online]. Praha: SÚJB, 2000 [cit. 2019-09-24]. Dostupné z: <https://www.sujb.cz/radiacni-ochrana/prirodni-zdroje-ionizujiciho-zareni/ozareni-z-prirodnich-zdroju-zareni/>
- [7] KÖRNER, Markus, Christof H. WEBER, Stefan WIRTH, Klaus-Jürgen PFEIFER, Maximilian F. REISER a Marcus TREITL. Advances in Digital Radiography: Physical Principles and System Overview. [cit. 2019-09-24]. Dostupné z: <https://pubs.rsna.org/doi/pdf/10.1148/rg.273065075>
- [8] Rozpadové řady. Encyklopedie fyziky [online]. 2006 [cit. 2019-09-24]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/809-rozpadove-rady>
- [9] Radiační poškození materiálů. Katedra fyziky materiálů [online]. [cit. 2019-09-24]. Dostupné z: [https://material.karlov.mff.cuni.cz/people/janecek/studenti/Fyzika\\_materialu2/RP\\_prednaska\\_rev09.pdf](https://material.karlov.mff.cuni.cz/people/janecek/studenti/Fyzika_materialu2/RP_prednaska_rev09.pdf)
- [10] Radiobiologie [online]. [cit. 2019-09-29]. Dostupné z: <http://fbmi.sirdik.org>
- [11] PENHAKER, Marek, AUGUSTYNEK, Martin. Zdravotnické elektrické přístroje 2. Ostrava: Vysoká škola báňská – Technická univerzita Ostrava, 2013. ISBN 978-80-248-3108-4.
- [12] PENHAKER, Marek. Lékařské terapeutické přístroje. Ostrava: VŠB – Technická univerzita Ostrava, 2007. ISBN 978-80-248-1558-9.

- [13] ULLMANN, Vojtěch. Jaderná a radiační fyzika. Astro Nukl Fyzika [online]. Ostrava [cit. 2019-09-29]. Dostupné z: <http://astronuklfyzika.cz/JadRadFyzika6.htm>
- [14] BIBBO, Giovanni a Lino PIOTTO. Background ionising radiation: a pictorial perspective. Australasian Physical & Engineering Sciences in Medicine [online]. 2014, 37(3), 575-581 [cit. 2019-09-29]. DOI: 10.1007/s13246-014-0286-5. ISSN 0158-9938. Dostupné z: <http://link.springer.com/10.1007/s13246-014-0286-5>
- [15] KUBENKOVÁ, Kristýna. Citlivost kazet pro nepřímou digitalizaci obrazu na přírodní radiační pozadí. Ostrava, 2019. Bakalářská práce. Ostravská univerzita. Vedoucí práce Ing. Mgr. Karol Korhelík, Ph. D.
- [16] HOLÍK, Zdeněk. Vliv záření na vlastnosti polymerů: Změna vybraných mechanických vlastností v závislosti na absorbované dávce záření. Zlín, 2013. Disertační práce. Univerzita Tomáše Bati ve Zlíně.
- [17] JAMROZOVÁ, Iveta. Modelování a analýza efektu ionizujícího záření na paměťových fóliích. Ostrava, 2018. Diplomová práce. VŠB – TUO.
- [18] VODÁKOVÁ, Andrea. Vliv sekundárního rentgenového záření na kvalitu skiagrafických snímků. Ostrava, 2018. Diplomová práce. VŠB – TUO.
- [19] ŠPANĚL, Michal a Vítězslav BERAN. Obrazové segmentační techniky [online]. Brno, 2006 [cit. 2016-12-09]. Dostupné z: <http://www.fit.vutbr.cz/~spanel/segmentace/>
- [20] WIRJADI, Oliver. Survey of 3d image segmentation methods: Models and algorithms in image processing. Kaiserslautern: Fraunhofer-Institut für Techno – und Wirtschaftsmathematik, 2007. ISSN 1434-9973.
- [21] PHAM, Dzung L., Chenyang XU a Jerry L. PRINCE. Current methods in medical image segmentation. Baltimore, Maryland, 2000, 27.
- [22] SURI, Jasjit S, David L WILSON a Swamy LAXMINARAYAN (eds.). Handbook of biomedical image analysis. 1st ed. New York: Kluwer Academic, c2005, xvi, 574 s. Topics in biomedical engineering international book series. ISBN 0306486075.
- [23] MALLAT, S. G. A wavelet tour of signal processing: the sparse way. 3rd ed. Boston: Elsevier/Academic Press, c2009. ISBN 978-0-12-374370-1
- [24] DHAWAN, Atam P. Medical image analysis. Hoboken: Wiley, c2003. IEEE Press series on biomedical engineering. ISBN 0-471-45131-2.

- [25] MCANDREW, Alasdair. Introduction to digital image processing with MATLAB. Boston: Thomson Course Technology, c2004. ISBN 0-534-40011-6.
- [26] K-Means Data Clustering. In: Towards data science [online]. Kanada, 2017 [cit. 2019-12-29]. Dostupné z: <https://towardsdatascience.com/k-means-data-clustering-bce3335d2203>
- [27] M. Dehakla, K. Djemal and M. Benyettou, 2011. Influence of Noise Distribution on Active Contour Models: Medical Images Segmentation. Asian Journal of Applied Sciences, 4: 101-111
- [28] Simple single-seeded region growing. In: MathWorks [online]. USA: The MathWorks, 2019 [cit. 2019-12-29]. Dostupné z: [https://ww2.mathworks.cn/matlabcentral/fileexchange/35269-simple-single-seeded-region-growing?s\\_tid=FX\\_rc3\\_behav](https://ww2.mathworks.cn/matlabcentral/fileexchange/35269-simple-single-seeded-region-growing?s_tid=FX_rc3_behav)
- [29] FISHER, Adrian. Cloud and Cloud-Shadow Detection in SPOT5 HRG Imagery with Automated Morphological Feature Extraction. In: ResearchGate [online]. [cit. 2019-12-29]. Dostupné z: [https://www.researchgate.net/figure/Two-examples-of-the-watershed-transform-applied-to-a-1-dimensional-signal-A-When\\_fig2\\_262985072](https://www.researchgate.net/figure/Two-examples-of-the-watershed-transform-applied-to-a-1-dimensional-signal-A-When_fig2_262985072)
- [30] Koncept umělé neuronové sítě. In: Matematická biologie [online]. Brno [cit. 2019-12-29]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analiza-a-hodnoceni-biologickych-dat--umela-inteligence--neuronove-site-jednotlivy-neuron--uvod-do-neuronovych-siti--koncept-umele-neuronove-site>
- [31] Polimaster [online]. Polimaster, 2020 [cit. 2019-12-29]. Dostupné z: <https://en.polimaster.com/catalog/personal-dosimeters/x-ray-and-gamma-radiation-personal-dosimeter-pm1621/>
- [32] LEHMANN, E. L. a George CASELLA. Theory of point estimation. 2nd ed. New York: Springer, c1998. ISBN 978-0-387-98502-2.
- [33] HENDL, Jan. Přehled statistických metod: analýza a metaanalýza dat. 3., přeprac. vyd. Praha: Portál, 2009. ISBN 978-80-7367-482-3.
- [34] Výpočet kvartilů Q1, Q2, Q3. HackMath [online]. HackMath.net, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.hackmath.net/cz/kalkulacka/vypocet-kvartilu-q1-q2-q3>
- [35] PRŮCHA, Ladislav. Popisná statistika [online]. Praha [cit. 2020-04-13]. Dostupné z: <https://math.feld.cvut.cz/prucha/mstp/7pu.pdf>
- [36] VACHTOVÁ, Jitka. Směrodatná odchylka  $\sigma$ . Statistika [online]. 2020 [cit. 2020-04-13]. Dostupné z: <https://www.ekovyp.cz/smerodatna-odchylka/>



- [37] NETOLICKÁ, Veronika. Testy normality. Přírodovědecká fakulta Univerzity Palackého v Olomouci: Katedra matematické analýzy a aplikací matematiky, 2008
- [38] Histogramme loi normale. Wikimedia Commons [online]. 2020 [cit. 2020-04-13]. Dostupné z: [https://commons.wikimedia.org/wiki/File:Histogramme\\_loi\\_normale.svg?uselang=cs](https://commons.wikimedia.org/wiki/File:Histogramme_loi_normale.svg?uselang=cs)
- [39] Kstest: One-sample Kolmogorov-Smirnov test. MathWorks [online]. The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/stats/kstest.html>
- [40] Vartestn: Multiple-sample tests for equal variances. MathWorks [online]. United States: The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/stats/vartestn.html>
- [41] Ranksum: Wilcoxon rank sum test. MathWorks [online]. United States: The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/stats/ranksum.html>
- [42] Kruskalwallis: Kruskal-Wallis test. MathWorks [online]. United States: The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/stats/kruskalwallis.html>
- [43] Multcompare: Multiple comparison test. MathWorks [online]. United States: The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/stats/multcompare.html>
- [44] Curve Fitting. MathWorks [online]. United States: The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/curvefit/curvefitting-app.html>
- [45] Linear and Nonlinear Regression. MathWorks [online]. United States: The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/curvefit/linear-and-nonlinear-regression.html>
- [46] Polynomial Models. MathWorks [online]. United States: The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/curvefit/polynomial.html>
- [47] WANER, Stefan. Linear and exponential regression [online]. 2008 [cit. 2020-04-13]. Dostupné z: <https://www.zweigmedia.com/RealWorld/calctopic1/regression.html>
- [48] Exponential Models. MathWorks [online]. United States: The MathWorks, 2020 [cit. 2020-04-13]. Dostupné z: <https://www.mathworks.com/help/curvefit/exponential.html>

## Přílohy

Příloha A:

### Tabulky

|   |     |
|---|-----|
| Tab. 1: Post-hoc analýza metodou Dunnové pro region 1 ve druhé sérii měření.....  | I   |
| Tab. 2: Post-hoc analýza metodou Dunnové pro region 2 ve druhé sérii měření.....  | I   |
| Tab. 3: Post-hoc analýza metodou Dunnové pro region 3 ve druhé sérii měření.....  | II  |
| Tab. 4: Post-hoc analýza metodou Dunnové pro region 4 ve druhé sérii měření.....  | II  |
| Tab. 5: Post-hoc analýza metodou Dunnové pro region 5 ve druhé sérii měření.....  | III |
| Tab. 6: Post-hoc analýza metodou Dunnové pro region 1 v první sérii měření .....  | III |
| Tab. 7: Post-hoc analýza metodou Dunnové pro region 2 v první sérii měření .....  | IV  |
| Tab. 8: Post-hoc analýza metodou Dunnové pro region 3 v první sérii měření .....  | IV  |
| Tab. 9: Post-hoc analýza metodou Dunnové pro region 4 v první sérii měření .....  | V   |
| Tab. 10: Post-hoc analýza metodou Dunnové pro region 5 v první sérii měření ..... | VI  |

### Obrázky

|  |      |
|--|------|
| Obr. 1: Lineární model pro počet vzorků v regionu 1 v závislosti na dávce (2. série).....      | VI   |
| Obr. 2: Exponenciální model pro počet vzorků v regionu 1 v závislosti na dávce (2. série) ..   | VII  |
| Obr. 3: Lineární model pro počet vzorků v regionu 2 v závislosti na dávce (2. série).....      | VII  |
| Obr. 4: Exponenciální model pro počet vzorků v regionu 2 v závislosti na dávce (2. série) ..   | VII  |
| Obr. 5: Lineární model pro počet vzorků v regionu 3 v závislosti na dávce (2. série).....      | VIII |
| Obr. 6: Exponenciální model pro počet vzorků v regionu 3 v závislosti na dávce (2. série) .    | VIII |
| Obr. 7: Lineární model pro počet vzorků v regionu 4 v závislosti na dávce (2. série).....      | VIII |
| Obr. 8: Exponenciální model pro počet vzorků v regionu 4 v závislosti na dávce (2. série) ...  | IX   |
| Obr. 9: Lineární model pro počet vzorků v regionu 1 v závislosti na dávce (1. série).....      | IX   |
| Obr. 10: Exponenciální model pro počet vzorků v regionu 1 v závislosti na dávce (1. série) .   | IX   |
| Obr. 11: Lineární model pro počet vzorků v regionu 3 v závislosti na dávce (1. série).....     | X    |
| Obr. 12: Exponenciální model pro počet vzorků v regionu 3 v závislosti na dávce (1. série) ... | X    |
| Obr. 13: Lineární model pro počet vzorků v regionu 4 v závislosti na dávce (1. série).....     | X    |
| Obr. 14: Exponenciální model pro počet vzorků v regionu 4 v závislosti na dávce (1. série) .   | XI   |

Příloha B:        Součástí DP je i složka, obsahující vstupní obrazy z 1. i 2. série měření a kódy v Matlab.

## Příloha A

Tab. 1: Post-hoc analýza metodou Dunnové pro region 1 ve druhé sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^6$ ] | p-hodnota |
|--------------------|---|-----------|
| 0 – 24             | 1,25  | $<<0,001$ |
| 0 – 1              | 1,34  | $<<0,001$ |
| 0 – 2              | 1,36  | $<<0,001$ |
| 0 – 3              | 1,44  | $<<0,001$ |
| 0 – 4              | 1,24  | $<<0,001$ |
| 24 – 1             | 0,09  | $<<0,001$ |
| 24 – 2             | 0,11  | $<<0,001$ |
| 24 – 3             | 0,19  | $<<0,001$ |
| 24 – 4             | -0,01   | $<<0,001$ |
| 1 – 2              | 0,02  | $<<0,001$ |
| 1 – 3              | 0,09  | $<<0,001$ |
| 1 – 4              | -0,11   | $<<0,001$ |
| 2 – 3              | 0,08  | $<<0,001$ |
| 2 – 4              | -0,12   | $<<0,001$ |
| 3 – 4              | -0,20   | $<<0,001$ |

Tab. 2: Post-hoc analýza metodou Dunnové pro region 2 ve druhé sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^4$ ] | p-hodnota |
|--------------------|---|-----------|
| 0 – 24             | 4,17  | $<<0,001$ |
| 0 – 1              | 5,05  | $<<0,001$ |
| 0 – 2              | 5,11  | $<<0,001$ |
| 0 – 3              | 5,23  | $<<0,001$ |
| 0 – 4              | 4,44  | $<<0,001$ |
| 24 – 1             | 0,88  | $<<0,001$ |
| 24 – 2             | 0,94  | $<<0,001$ |
| 24 – 3             | 1,06  | $<<0,001$ |
| 24 – 4             | 0,27  | $<<0,001$ |
| 1 – 2              | 0,06  | $<<0,001$ |
| 1 – 3              | 0,18  | $<<0,001$ |
| 1 – 4              | -0,61   | $<<0,001$ |
| 2 – 3              | 0,12  | $<<0,001$ |
| 2 – 4              | -0,67   | $<<0,001$ |

|       |       |         |
|-------|-------|---------|
| 3 – 4 | -0,79 | <<0,001 |
|-------|-------|---------|

Tab. 3: Post-hoc analýza metodou Dunnové pro region 3 ve druhé sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^4$ ] | p-hodnota |
|--------------------|---|-----------|
| 0 – 24             | 5,98  | <<0,001   |
| 0 – 1              | 6,91  | <<0,001   |
| 0 – 2              | 6,94  | <<0,001   |
| 0 – 3              | 7,37  | <<0,001   |
| 0 – 4              | 6,29  | <<0,001   |
| 24 – 1             | 0,93  | <<0,001   |
| 24 – 2             | 0,96  | <<0,001   |
| 24 – 3             | 1,38  | <<0,001   |
| 24 – 4             | 0,31  | <<0,001   |
| 1 – 2              | 0,03  | <<0,001   |
| 1 – 3              | 0,46  | <<0,001   |
| 1 – 4              | -0,62   | <<0,001   |
| 2 – 3              | 0,43  | <<0,001   |
| 2 – 4              | -0,65   | <<0,001   |
| 3 – 4              | -1,07   | <<0,001   |

Tab. 4: Post-hoc analýza metodou Dunnové pro region 4 ve druhé sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^4$ ] | p-hodnota |
|--------------------|---|-----------|
| 24 – 1             | 2,12  | <<0,001   |
| 24 – 2             | 1,86  | <<0,001   |
| 24 – 3             | 1,98  | <<0,001   |
| 24 – 4             | 2,15  | <<0,001   |
| 1 – 2              | -0,25   | <<0,001   |
| 1 – 3              | -0,14   | <<0,001   |
| 1 – 4              | 0,03  | <<0,001   |
| 2 – 3              | 0,12  | <<0,001   |
| 2 – 4              | 0,29  | <<0,001   |
| 3 – 4              | 0,17  | <<0,001   |

Tab. 5: Post-hoc analýza metodou Dunnové pro region 5 ve druhé sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^5$ ] | p-hodnota |
|--------------------|---|-----------|
| 0 – 24             | 9,05  | $<<0,001$ |
| 0 – 1              | 9,58  | $<<0,001$ |
| 0 – 2              | 9,61  | $<<0,001$ |
| 0 – 3              | 9,48  | $<<0,001$ |
| 0 – 4              | 9,87  | $<<0,001$ |
| 24 – 1             | 0,53  | $<<0,001$ |
| 24 – 2             | 0,56  | $<<0,001$ |
| 24 – 3             | 0,43  | $<<0,001$ |
| 24 – 4             | 0,82  | $<<0,001$ |
| 1 – 2              | 0,03  | $<<0,001$ |
| 1 – 3              | -0,09   | $<<0,001$ |
| 1 – 4              | 0,29  | $<<0,001$ |
| 2 – 3              | -0,13   | $<<0,001$ |
| 2 – 4              | 0,26  | $<<0,001$ |
| 3 – 4              | 0,39  | $<<0,001$ |

Tab. 6: Post-hoc analýza metodou Dunnové pro region 1 v první sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^6$ ] | p-hodnota |
|--------------------|---|-----------|
| 0 – 24             | 0,92  | $<<0,001$ |
| 0 – 48             | 1,41  | $<<0,001$ |
| 0 – 4              | 1,49  | $<<0,001$ |
| 0 – 8              | 0,86  | $<<0,001$ |
| 0 – 16             | 1,48  | $<<0,001$ |
| 0 – 32             | 0,96  | $<<0,001$ |
| 24 – 48            | 0,49  | $<<0,001$ |
| 24 – 4             | 0,57  | $<<0,001$ |
| 24 – 8             | -0,05   | $<<0,001$ |
| 24 – 16            | 0,56  | $<<0,001$ |
| 24 – 32            | 0,04  | $<<0,001$ |
| 48 – 4             | 0,07  | $<<0,001$ |
| 48 – 8             | -0,55   | $<<0,001$ |
| 48 – 16            | 0,06  | $<<0,001$ |
| 48 – 32            | -0,45   | $<<0,001$ |

|         |       |         |
|---------|-------|---------|
| 4 – 8   | -0,62 | <<0,001 |
| 4 – 16  | -0,01 | <<0,001 |
| 4 – 32  | -0,52 | <<0,001 |
| 8 – 16  | 0,61  | <<0,001 |
| 8 – 32  | 0,09  | <<0,001 |
| 16 – 32 | -0,52 | <<0,001 |

Tab. 7: Post-hoc analýza metodou Dunnové pro region 2 v první sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^4$ ] | p-hodnota |
|--------------------|---|-----------|
| 0 – 24             | 0,60  | <<0,001   |
| 0 – 48             | 1,46  | <<0,001   |
| 0 – 4              | 1,47  | <<0,001   |
| 0 – 8              | 0,54  | <<0,001   |
| 0 – 16             | 1,45  | <<0,001   |
| 0 – 32             | 0,67  | <<0,001   |
| 24 – 48            | 0,86  | <<0,001   |
| 24 – 4             | 0,87  | <<0,001   |
| 24 – 8             | -0,07   | <<0,001   |
| 24 – 16            | 0,85  | <<0,001   |
| 24 – 32            | 0,07  | <<0,001   |
| 48 – 4             | 0,01  | <<0,001   |
| 48 – 8             | -0,93   | <<0,001   |
| 48 – 16            | -0,01   | <<0,001   |
| 48 – 32            | -0,79   | <<0,001   |
| 4 – 8              | -0,92   | <<0,001   |
| 4 – 16             | -0,02   | <<0,001   |
| 4 – 32             | -0,81   | <<0,001   |
| 8 – 16             | 0,92  | <<0,001   |
| 8 – 32             | 0,13  | <<0,001   |
| 16 – 32            | -0,79   | <<0,001   |

Tab. 8: Post-hoc analýza metodou Dunnové pro region 3 v první sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^5$ ] | p-hodnota |
|--------------------|---|-----------|
| 0 – 24             | 1,09  | <<0,001   |
| 0 – 48             | 2,33  | <<0,001   |


|         |       |         |
|---------|-------|---------|
| 0 – 4   | 2,29  | <<0,001 |
| 0 – 8   | 1,05  | <<0,001 |
| 0 – 16  | 2,28  | <<0,001 |
| 0 – 32  | 1,19  | <<0,001 |
| 24 – 48 | 1,24  | <<0,001 |
| 24 – 4  | 1,20  | <<0,001 |
| 24 – 8  | -0,03 | <<0,001 |
| 24 – 16 | 1,19  | <<0,001 |
| 24 – 32 | 0,10  | <<0,001 |
| 48 – 4  | -0,03 | <<0,001 |
| 48 – 8  | -1,28 | <<0,001 |
| 48 – 16 | -0,04 | <<0,001 |
| 48 – 32 | -1,14 | <<0,001 |
| 4 – 8   | -1,24 | <<0,001 |
| 4 – 16  | -0,01 | <<0,001 |
| 4 – 32  | -1,10 | <<0,001 |
| 8 – 16  | 1,23  | <<0,001 |
| 8 – 32  | 0,14  | <<0,001 |
| 16 – 32 | -1,09 | <<0,001 |

Tab. 9: Post-hoc analýza metodou Dunnové pro region 4 v první sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^5$ ] | p-hodnota |
|--------------------|---|-----------|
| 24 – 48            | 1,32  | <<0,001   |
| 24 – 4             | 1,19  | <<0,001   |
| 24 – 8             | 0,04  | <<0,001   |
| 24 – 16            | 1,14  | <<0,001   |
| 24 – 32            | 0,18  | <<0,001   |
| 48 – 4             | -0,12   | <<0,001   |
| 48 – 8             | -1,28   | <<0,001   |
| 48 – 16            | -0,18   | <<0,001   |
| 48 – 32            | -1,14   | <<0,001   |
| 4 – 8              | -1,15   | <<0,001   |
| 4 – 16             | -0,05   | <<0,001   |
| 4 – 32             | -1,01   | <<0,001   |
| 8 – 16             | 1,10  | <<0,001   |
| 8 – 32             | 0,14  | <<0,001   |
| 16 – 32            | -0,96   | <<0,001   |


Tab. 10: Post-hoc analýza metodou Dunnové pro region 5 v první sérii měření

| Srovnávaná skupina | Průměrný rozdíl mediánů<br>jasových složek [ $\cdot 10^6$ ] | p-hodnota |
|--------------------|---|-----------|
| 0 – 24             | 1,08  | $<<0,001$ |
| 0 – 48             | 1,48  | $<<0,001$ |
| 0 – 4              | 1,45  | $<<0,001$ |
| 0 – 8              | 1,12  | $<<0,001$ |
| 0 – 16             | 1,44  | $<<0,001$ |
| 0 – 32             | 1,10  | $<<0,001$ |
| 24 – 48            | 0,40  | $<<0,001$ |
| 24 – 4             | 0,37  | $<<0,001$ |
| 24 – 8             | 0,04  | $<<0,001$ |
| 24 – 16            | 0,36  | $<<0,001$ |
| 24 – 32            | 0,02  | $<<0,001$ |
| 48 – 4             | -0,02   | $<<0,001$ |
| 48 – 8             | -0,36   | $<<0,001$ |
| 48 – 16            | -0,03   | $<<0,001$ |
| 48 – 32            | -0,37   | $<<0,001$ |
| 4 – 8              | -0,33   | $<<0,001$ |
| 4 – 16             | -0,01   | $<<0,001$ |
| 4 – 32             | -0,34   | $<<0,001$ |
| 8 – 16             | 0,32  | $<<0,001$ |
| 8 – 32             | -0,02   | $<<0,001$ |
| 16 – 32            | -0,34   | $<<0,001$ |




Obr. 1: Lineární model pro počet vzorků v regionu 1 v závislosti na dávce (2. série)







Obr. 2: Exponenciální model pro počet vzorků v regionu 1 v závislosti na dávce (2. série)




Obr. 3: Lineární model pro počet vzorků v regionu 2 v závislosti na dávce (2. série)




Obr. 4: Exponenciální model pro počet vzorků v regionu 2 v závislosti na dávce (2. série)




Obr. 5: Lineární model pro počet vzorků v regionu 3 v závislosti na dávce (2. série)




Obr. 6: Exponenciální model pro počet vzorků v regionu 3 v závislosti na dávce (2. série)




Obr. 7: Lineární model pro počet vzorků v regionu 4 v závislosti na dávce (2. série)




Obr. 8: Exponenciální model pro počet vzorků v regionu 4 v závislosti na dávce (2. série)




Obr. 9: Lineární model pro počet vzorků v regionu 1 v závislosti na dávce (1. série)




Obr. 10: Exponenciální model pro počet vzorků v regionu 1 v závislosti na dávce (1. série)




Obr. 11: Lineární model pro počet vzorků v regionu 3 v závislosti na dávce (1. série)



Obr. 12: Exponenciální model pro počet vzorků v regionu 3 v závislosti na dávce (1. série)



Obr. 13: Lineární model pro počet vzorků v regionu 4 v závislosti na dávce (1. série)



Obr. 14: Exponenciální model pro počet vzorků v regionu 4 v závislosti na dávce (1. série)